

ZONGULDAK BÜLENT ECEVİT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

TARIMSAL ORTAMLARDA BİTKİ HASTALIKLARININ GERÇEK ZAMANLI
TESPİTİ İÇİN YAPAY ZEKÂ TABANLI MELEZ ALGORİTMA TASARIMI

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

İLAYDA YAĞ

TEMMUZ 2023

ZONGULDAK BÜLENT ECEVİT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

TARIMSAL ORTAMLARDA BİTKİ HASTALIKLARININ GERÇEK ZAMANLI
TESPİTİ İÇİN YAPAY ZEKÂ TABANLI MELEZ ALGORİTMA TASARIMI

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

İlayda YAĞ

DANIŞMAN: Doç. Dr. Aytaç ALTAN

ZONGULDAK

Temmuz 2023

KABUL:

İlayda YAĞ tarafından hazırlanan “Tarımsal Ortamlarda Bitki Hastalıklarının Gerçek Zamanlı Tespiti için Yapay Zekâ Tabanlı Melez Algoritma Tasarımı” başlıklı bu çalışma jürimiz tarafından değerlendirilerek Zonguldak Bülent Ecevit Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalında Yüksek Lisans Tezi olarak oybirliğiyle kabul edilmiştir. 20/07/2023

Danışman: Doç. Dr. Aytaç ALTAN

Zonguldak Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü

Üye: Dr. Öğr. Üyesi Ceren KAYA

Zonguldak Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Biyomedikal Mühendisliği Bölümü

Üye: Dr. Öğr. Üyesi Ali ÇALIM

Bolu Abant İzzet Baysal Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü

ONAY:

Yukarıdaki imzaların, adı geçen öğretim üyelerine ait olduğunu onaylarım. .../.../2023

Prof. Dr. Fikret GÖLGELEYEN
Fen Bilimleri Enstitüsü Müdürü



“Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, bu çalışmadan kaynaklanmayan bütün atıfları yaptığımı beyan ederim.”

İlayda YAĞ

ÖZET

Yüksek Lisans Tezi

TARIMSAL ORTAMLARDA BİTKİ HASTALIKLARININ GERÇEK ZAMANLI TESPİTİ İÇİN YAPAY ZEKÂ TABANLI MELEZ ALGORİTMA TASARIMI

İlayda YAĞ

Zonguldak Bülent Ecevit Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Aytaç ALTAN

Temmuz 2023, 67 Sayfa

Dünya genelinde kıtlık ve gıda güvensizliğinin önemli bir nedeni olan bitki hastalıklarının erken tespiti ve önlenmesi, tarımsal ürün verimliliğinin artırılması açısından oldukça önemlidir. Bitki hastalığının sadece erken tespiti değil aynı zamanda türünün belirlenmesi de uygun tedavinin yapılmasında kritik rol oynamaktadır. Bitki hastalıklarının ve çeşitlerinin belirlenmesinde sıklıkla kullanılan gözle muayenenin yorucu ve insan hatasına açık olması, bitki hastalıklarının tespitinde otomatik olarak yüksek doğrulukta ve düşük hesaplama maliyetiyle sınıflandırabilen algoritmaların geliştirilmesini gerektirmektedir. Bu tezde elma, üzüm ve domates bitkilerinden oluşan görüntü veri setinin özellikleri, Biorthogonal, Coiflets, Daubechies, Fejer-Korovkin ve Symlets gibi dalgacık aileleri kullanılarak İki Boyutlu-Ayrık Dalgacık Dönüşümü (Two-Dimensional Discrete Wavelet Transform-2D-DWT) ile çıkarılmaktadır. Her aile için sınıflandırıcı performansını yüksek tutan özellikler popülasyon tabanlı meta sezgisel Çiçek Tozlaşma Algoritması (Flower Pollination Algorithm-FPA) ve Destek Vektör Makinesi (Support Vector Machine-SVM) ile oluşan sarmalayıcı yaklaşımla seçilmektedir. Önerilen optimizasyon algoritmasının performansı Parçacık Sürü Optimizasyonu (Particle Swarm Optimization-PSO) algoritması ile karşılaştırılmaktadır. Daha

ÖZET (devam ediyor)

sonra Evrişimli Sinir Ağı (Convolutional Neural Network- CNN) sınıflandırıcısı için sınıflandırma performansını yüksek tutabilecek en düşük öznitelik sayısı kullanılarak sınıflandırma performansı elde edilmektedir. Modelin karmaşıklığını en aza indirmek ve model hiper parametre problemiyle başa çıkabilmek için öznitelik çıkarma katmanı olmayan tek bir sınıflandırma katmanına sahip CNN sınıflandırıcısı kullanılmaktadır. Elde edilen model, İnsansız Hava Aracı (İHA) üzerindeki NVIDIA Jetson Nano geliştirici kitine gömülerek elma, üzüm ve domates bitkilerinde gerçek zamanlı sınıflandırma testleri yapılmaktadır. Elde edilen deneysel sonuçlar, önerilen modelin belirtilen bitki yaprak hastalıklarını gerçek zamanlı olarak yüksek doğrulukla sınıflandırdığını göstermektedir. Ayrıca, hesaplama karmaşıklığı düşük optimizasyon algoritması ile en az sayıda öznitelik seçilerek oluşturulan sağlam melez sınıflandırma modelinin bitki yaprak hastalıklarını gerçek zamanlı ve hassas bir şekilde sınıflandırabildiği sonucuna varılmaktadır.

Anahtar Kelimeler: Tarımsal bitki, hastalık sınıflandırması, ayırık dalgacık dönüşümü, sinyal işleme, çiçek tozlaşma optimizasyonu, yapay zekâ.

Bilim Kodu: 608.04.06, 608.05.00, 608.05.02

ABSTRACT

M. Sc. Thesis

DESIGN OF AN ARTIFICIAL INTELLIGENCE BASED HYBRID ALGORITHM FOR REAL-TIME DETECTION OF PLANT DISEASES IN AGRICULTURAL ENVIRONMENTS

İlayda YAĞ

**Zonguldak Bülent Ecevit University
Graduate School of Natural and Applied Sciences
Department of Electrical and Electronics Engineering**

Thesis Advisor: Assoc. Prof. Dr. Aytaç ALTAN

July 2023, 67 Pages

The early detection and prevention of plant diseases that are an important cause of famine and food insecurity worldwide are very important for increasing agricultural product productivity. Not only the early detection of the plant disease, but also the determination of its type play a critical role in the appropriate treatment. The fact that visual inspection, which is frequently used in determining plant disease and types, is tiring and prone to human error, necessitated the development of algorithms that can automatically classify plant disease with high accuracy and low computational cost. In this thesis, the features of the image dataset consisting of apple, grape, and tomato plants are extracted by a Two-Dimensional Discrete Wavelet Transform (2D-DWT) using wavelet families such as Biorthogonal, Coiflets, Daubechies, Fejer–Korovkin, and Symlets. Features that keep classifier performance high for each family are selected by the wrapper approach, consisting of the population-based metaheuristics Flower Pollination Algorithm (FPA) and Support Vector Machine (SVM). The performance of the proposed optimization algorithm is compared with the Particle Swarm Optimization Algorithm (PSO). Afterwards, the classification performance is obtained by using the lowest number of features

ABSTRACT (continued)

that can keep the classification performance high for the Convolutional Neural Network (CNN) classifier. The CNN classifier with a single layer of classification without a feature extraction layer is used to minimize the complexity of the model and to deal with the model hyperparameter problem. The obtained model is embedded in the NVIDIA Jetson Nano developer kit on the Unmanned Aerial Vehicle (UAV), and real-time classification tests are performed on apple, grape, and tomato plants. The experimental results obtained show that the proposed model classifies the specified plant leaf diseases in real time with high accuracy. Moreover, it is concluded that the robust hybrid classification model, which is created by selecting the lowest number of features with the optimization algorithm with low computational complexity, can classify plant leaf diseases in real time with precision.

Keywords: Agricultural plant, disease classification, discrete wavelet transform, signal processing, flower pollination optimization, artificial intelligence.

Science Code: 608.04.06, 608.05.00, 608.05.02

TEŐEKKÜR

Tez alıřmasında, arařtırmanın yrtlmesi ve sonulanmasına kadar deęerli yardım ve katkılarıyla beni ynlendiren danıřmanım saygıdeęer hocam Do. Dr. Ayta ALTAN'a teőekkrlerimi sunarım.

Yksek lisans tez alıřmam, TBİTAK Bilim İnsanı Destek Programları Bařkanlıęı (BİDEB) 2210-Yurt İi Yksek Lisans Burs Programları kapsamında 2210-C Yurt İi ncelikli Alanlar Yksek Lisans Burs Programı tarafından desteklenmiřtir. TBİTAK BİDEB'e teőekkrlerimi sunarım.

Her zaman ve tm tez alıřmam boyunca maddi manevi emek ve destekleriyle yanımda olan bařta deęerli annem Fatma İSKENDER olmak zere ok deęerli aileme ve arkadařlarıma saygı ve en iten teőekkrlerimi sunarım.



İÇİNDEKİLER

	<u>Sayfa</u>
KABUL:	ii
ÖZET	iii
ABSTRACT	v
TEŞEKKÜR	vii
İÇİNDEKİLER.....	ix
ŞEKİLLER DİZİNİ.....	xiii
ÇİZELGELER DİZİNİ	xv
SİMGELER VE KISALTMALAR DİZİNİ.....	xvii
BÖLÜM 1 GİRİŞ	1
BÖLÜM 2 TARIMSAL ORTAMLARDA BİTKİ HASTALIKLARI VE HASTALIĞA MÜDAHALE	7
2.1 BİTKİ HASTALIKLARININ TESPİTİNİN BAŞLAMASI VE MÜDAHALELER.....	7
2.2 BİTKİ HASTALIKLARININ BELİRTİLERİ	9
2.2.1 Bakteriyel Hastalık Belirtileri	10
2.2.2 Viral Hastalık Belirtileri	10
2.2.3 Mantar Hastalığı Belirtileri	10
2.3 BİTKİ HASTALIKLARININ TESPİT YÖNTEMLERİ	10
2.3.1 Görsel İnceleme	11
2.3.2 Mikroskopik Analiz	12
2.3.3 Moleküler Teknikler	12
2.3.4 Serolojik Testler	13
2.3.5 Bitki Doku Kültürleri.....	13
2.3.6 Spektroskopik ve Görüntüleme Teknikleri.....	13

İÇİNDEKİLER (devam ediyor)

	<u>Sayfa</u>
2.3.7 Hastalık Tespiti İçin Bitki Uçucu Organik Bileşiklerinin Profili	15
2.4 BİTKİ HASTALIKLARIYLA MÜCADELE YÖNTEMLERİ.....	15
2.4.1 Pestisitler ve Zararları	16
2.5 İNCELENEN BİTKİ YAPRAK HASTALIKLARI	17
2.5.1 Elma Siyah Çürüklük.....	17
2.5.2 Elma Memeli Mantarı.....	18
2.5.3 Elma Kara Leke	18
2.5.4 Üzüm Siyah Çürüklük	19
2.5.5 Üzüm Siyah Kızamık.....	20
2.5.6 Üzüm Yaprak Yanıklığı.....	20
2.5.7 Domates Bakteriyel Benek	21
2.5.8 Domates Geç Yanıklık.....	22
2.5.9 Domates Sarı Yaprak Kıvrıcılık Virüsü.....	23
BÖLÜM 3 BİTKİ HASTALIKLARININ TEŞHİSİ VE SINIFLANDIRILMASI	25
3.1 AYRIK DALGACIK DÖNÜŞÜMÜ	25
3.2 ÇOKLU ÇÖZÜNÜRLÜK ANALİZİ.....	27
3.3 DALGACIK AİLELERİ	28
3.3.1 Biorthogonal Dalgacık.....	28
3.3.2 Coiflet Dalgacık.....	29
3.3.3 Daubechies Dalgacık	30
3.3.4 Fejer-Korovkin Dalgacık	32
3.3.5 Symlets Dalgacık	32
3.4 İKİ BOYUTLU AYRIK DALGACIK DÖNÜŞÜMÜ	33
3.5 ÇİÇEK TOZLAŞMA ALGORİTMASI.....	35
3.6 EVRİŞİMLİ SİNİR AĞI SINIFLANDIRICISI	38
3.7 SINIFLANDIRMA İÇİN PERFORMANS METRİKLERİ	39
3.8 BİTKİ YAPRAK HASTALIĞI SINIFLANDIRILMASI İÇİN ÖNERİLEN METODOLOJİNİN ÇERÇEVESİ	40

İÇİNDEKİLER (devam ediyor)

	<u>Sayfa</u>
BÖLÜM 4 DENEYSEL SONUÇLAR VE TARTIŞMA	43
4.1 VERİ SETİ	43
4.2 DALGACIK AİLELERİ İLE 2D-DWT UYGULAMASI.....	46
4.3 İSTATİSTİKSEL VE ENTROPİ TEMELLİ ÖZELLİKLERİN ÇIKARILMASI	47
4.4 FPA-SVM YAKLAŞIMI İLE ÖZELLİK SEÇİMİ.....	49
4.5 BİTKİ YAPRAK HASTALIKLARI SINIFLANDIRMA MODELLERİNİN DEĞERLENDİRİLMESİ VE TARTIŞMA	52
BÖLÜM 5 SONUÇLAR VE ÖNERİLER.....	59
KAYNAKLAR.....	61
ÖZGEÇMİŞ	67



ŞEKİLLER DİZİNİ

<u>No</u>	<u>Sayfa</u>
Şekil 3.1 Çalışmada kullanılan her bir dalgacık türü için en iyi sınıflandırma performansını sağlayan dalgacıkların ölçekleme ve ana dalgacık fonksiyonu.	35
Şekil 3.2 FPA'daki tozlaşma türleri ve tozlayıcılar.	37
Şekil 3.3 Gerçek zamanlı olarak bitki yaprak hastalıklarını sınıflandırmak için önerilen sağlam melez modelin çerçevesi.	41
Şekil 4.1 Elma bitkisinin sağlıklı ve hastalıklı sınıflarına ait yaprak görüntüsü örnekleri.	45
Şekil 4.2 Üzüm bitkisinin sağlıklı ve hastalıklı sınıflarına ait yaprak görüntüsü örnekleri.	45
Şekil 4.3 Domates bitkisinin sağlıklı ve hastalıklı sınıflarına ait yaprak görüntüsü örnekleri.	46
Şekil 4.4 a) Biorthogonal, b) Coiflet, c) Daubechies, d) Fejer–Korovkin ve e) Simlet dalgacık aileleri için FPA'nın tüm yinelemelerinin seçilen özelliklerinin ısı haritası.	51
Şekil 4.5 Gerçek zamanlı testinde kullanılan insansız hava aracı.	56
Şekil 4.6 a) Biorthogonal, b) Coiflets, c) Daubechies, d) Fejer–Korovkin ve e) Simlets dalgacık aileleri için çalışmada kullanılan sınıflandırıcıların performansları.	57
Şekil 4.7 Önerilen elma, üzüm ve domates bitki yaprak hastalığı sınıflandırma modeli için karışıklık matrisi.	58



ÇİZELGELER DİZİNİ

<u>No</u>	<u>Sayfa</u>
Çizelge 2.1 Bitki hastalığı tespitinde kullanılan doğrudan yöntem ve dolaylı yöntem çeşitleri.	11
Çizelge 2.2 Bitki hastalıklarının ve özelliklerinin tespiti için temel tekniklerin karşılaştırılması.	11
Çizelge 4.1 Çalışmada kullanılan dalgacık aileleri ve filtre uzunlukları.	46
Çizelge 4.2 Görüntü matrislerinden çıkarılan özelliklerin dizin etiketleri.	47
Çizelge 4.3 İstatistiksel ve entropi tabanlı özellikler ve denklemleri.	48
Çizelge 4.4 Çalışmada kullanılan sarmalayıcı özellik seçim yaklaşımlarının parametre değerleri.	50
Çizelge 4.5 FPA-SVM sarmalayıcı yaklaşımıyla seçilen özellikler için sınıflandırıcıların performansı.	53
Çizelge 4.6 PSO-SVM sarmalayıcı yaklaşımı ile seçilen özellikler için sınıflandırıcıların performansı.	54
Çizelge 4.7 En iyi sınıflandırma performansını sağlayan dalgacık aileleri için önerilen FPA-SVM ve PSO-SVM sarmalayıcı yaklaşımları tarafından seçilen özelliklerle oluşturulan çeşitli sınıflandırıcıların performanslarının karşılaştırılması.	56



SİMGELER VE KISALTMALAR DİZİNİ

SİMGELER

$\psi(t)$: Temel dalgacık
$\psi(s)$: Temel dalgacığın Laplace dönüşümü
C_ψ	: Dalgacık sabiti
$\psi_{a,b}(t)$: Dalgacık temel fonksiyonu kümesi
a	: Temel fonksiyon ölçeği
b	: Temel fonksiyonun t boyunca ötelenmiş konumu
t	: Zaman
$x(t)$: Analiz edilmek istenen sinyal
$W(a, b)$: $x(t)$ 'nin sürekli dalgacık dönüşümü
$f(t)$: Ters sürekli dalgacık dönüşümü
m	: Frekans konumu
n	: Zaman konumu
a_0^m	: Ölçekleme parametresi
$na_0^m b_0$: Öteleme parametresi
$\varphi_{m,n}[k]$: Ölçekleme fonksiyonu
$\psi_{m,n}[k]$: Dalgacık fonksiyonu
$h[n]$: Alçak geçiren filtre
$g[n]$: Yüksek geçiren filtre
$\varphi, \tilde{\varphi}$: Farklı MRA üretebilen iki ölçekleme fonksiyonu
$\psi, \tilde{\psi}$: Farklı MRA üretebilen iki dalgacık fonksiyonu
$h_0(k), \tilde{h}_0(k)$: Ölçekleme fonksiyonu için ikili filtre katsayısı
$g_1(k), \tilde{g}_1(k)$: Dalgacık fonksiyonu için ikili filtre katsayısı
H	: Coiflets filtresi
γ	: Coiflets dalgacığı öteleme parametresi
M	: Coiflets dalgacığı kaybolma momenti

SİMGELER VE KISALTMALAR DİZİNİ (devam ediyor)

$N - 1$: Coiflets ölçekleme fonksiyonu kaybolma momenti
N	: Kaybolan dalgacık momentlerinin sayısı
m^*	: Yerelleştirme parametresi
p_m	: Ölçeklendirme filtre katsayıları vektörü
r_{N-1-m}	: Dalgacık filtre katsayıları vektörü
$ m_0^n(\xi) ^2$: Fejer-Korovkin filtresi
$L^2(R)$: Ortonormal bir temele denk gelen dalgacık
$\psi^H(x, y)$: Yatay yöne karşılık gelen iki boyutlu dalgacık fonksiyonu
$\psi^V(x, y)$: Dikey yöne karşılık gelen iki boyutlu dalgacık fonksiyonu
$\psi^D(x, y)$: Çapraz yöne karşılık gelen iki boyutlu dalgacık fonksiyonu
$\varphi(x, y)$: İki boyutlu ölçekleme fonksiyonu
$\psi(x, y)$: İki boyutlu dalgacık fonksiyonu
W_φ	: İki boyutlu ayrık dalgacık dönüşümü ölçekleme fonksiyonu
W_ψ	: İki boyutlu ayrık dalgacık dönüşümü dalgacık fonksiyonu
p	: Yerel ve global arama arasındaki dengenin yüzdelik ifadesi
X_1^t	: t yinelemesindeki çözüm vektörü
g_*	: Mevcut yinelemedeki tüm çözümler arasında mevcut en iyi çözüm
L	: Lévy uçuş dağılımı
$\Gamma(\lambda)$: Standart gama fonksiyonu
X_j^t, X_k^t	: Aynı bitkinin farklı çiçeklerinin polen demetleri
ε	: Rastgele yerel tozlaşma mesafesi
N_*	: Yineleme sayısı
fn	: Uygunluk fonksiyonu değeri
p_*	: Seçilen özneliklerin sayısı
$F1 - skor$: Hatırlama ve kesinliğin harmonik ortalaması
$I_j^i(x, y)$: Görüntü matrisi
$\gamma_R(\varepsilon_C)$: Sınıflandırıcının sınıflandırma hata oranı
μ	: Sınıflandırma kalitesi
σ	: Alt küme uzunluğu

SİMGELER VE KISALTMALAR DİZİNİ (devam ediyor)

KISALTMALAR

2D	: Two-Dimensional (İki-Boyutlu)
2D-DWT	: Two-Dimensional Discrete Wavelet Transform (İki Boyutlu Ayrık Dalgacık Dönüşümü)
AB	: Avrupa Birliği
AI	: Artificial Intelligence (Yapay Zekâ)
CFU	: Colony Forming Unit (Koloni Oluşturan Birim)
CNN	: Convolutional Neural Network (Evrışimli Sinir Ağı)
CWT	: Continuous Wavelet Transform (Sürekli Dalgacık Dönüşümü)
D	: Diagonal (Çapraz)
DNA	: Deoxyribonucleic Acid (Deoksiribo Nükleik Asit)
DWT	: Discrete Wavelet Transform (Ayrık Dalgacık Dönüşümü)
EFSA	: European Food Safety Authority (Avrupa Gıda Güvenliği Otoritesi)
ELISA	: Enzyme-Linked Immunosorbent Assay (Enzime Bağlı Bağışıklık Deneyi)
FAO	: Food and Agriculture Organization (Gıda ve Tarım Örgütü)
FCM	: Flow Cytometry (Akış Sitometrisi)
FISH	: Fluorescence In-Situ Hybridization (Floresan Yerde Hibridizasyon)
FN	: False Negative (Yanlış Negatif)
FP	: False Positive (Yanlış Doğru)
FPA	: Flower Pollination Algorithm (Çiçek Tozlaşma Algoritması)
FT	: Fourier Transform (Rastgele Transform)
FTIR	: Fourier Transform Infrared (Fourier Transform Kızılötesi)
GA	: Genetic Algorithm (Genetik Algoritma)
GLCM	: Gray Level Co-Occurrence Matrix (Gri Seviyeli Birlikte Oluşum Matrisi)
H	: Horizontal (Yatay)
HSV	: Hue Saturation Value (Ton Doygunluk Değeri)
IF	: Immunofluorescence (İmmünofloresans)
İHA	: İnsansız Hava Aracı
kNN	: k-Nearest Neighbor (k-en Yakın Komşu)

SİMGELER VE KISALTMALAR DİZİNİ (devam ediyor)

LBP	: Local Binary Patterns (Yerel İkili Desenler)
MCV	: Maximum Column Vector (Maksimum Sütun Vektörü)
MRA	: Multi Resolution Analysis (Çoklu Çözünürlük Analizi)
MRV	: Maximum Row Vector (Maksimum Satır Vektörü)
NMR	: Nuclear Magnetic Resonance (Nükleer Manyetik Rezonans)
PCA	: Principle Component Analysis (Temel Bileşen Analizi)
PCR	: Polymerase Chain Reaction (Polimeraz Zincir Reaksiyonu)
PSO	: Particle Swarm Optimization (Parçacık Sürüsü Optimizasyonu)
RF	: Random Forest
RNA	: Ribonucleic Acid (Ribonükleik Asit)
RGB	: Red Green Blue (Kırmızı Yeşil Mavi)
SGD	: Stochastic Gradient Descent (Stokastik Gradyan İnişi)
STFT	: Short-Term Fourier Transform (Kısa Süreli Fourier Dönüşümü)
SVM	: Support Vector Machine (Destek Vektör Makinesi)
TN	: True Negative (Gerçek Negatif)
TP	: True Positive (Gerçek Pozitif)
UAV	: Unmanned Aerial Vehicle
V	: Vertical (Dikey)
VOC	: Volatile Organic Compounds (Uçucu Organik Bileşikler)
WT	: Wavelet Transform (Dalgacık Dönüşümü)

BÖLÜM 1

GİRİŞ

Bitkinin normal büyümesini bozan anormal bir durum olarak tanımlanan bitki hastalığı, tarım endüstrisindeki ekonomik kayıpların ana nedenlerinden biridir. Bitki hastalığının erken teşhisi, tarımsal ürün verimliliğini artırmak için kritik öneme sahiptir. Bu çalışmada elma, üzüm ve domates bitkilerindeki hastalıkların gerçek zamanlı olarak sınıflandırılmasına izin veren makine öğrenmesi ve derin öğrenme algoritmalarını içeren sürü optimizasyonu destekli özellik seçimine dayalı yeni bir sağlam melez sınıflandırma modeli geliştirilmektedir. Bu sayede bitki hastalığını erken dönemde teşhis etmek ve uygun tedaviyi uygulamak mümkün olmaktadır.

Dünya nüfusundaki hızlı artış ve mevcut nüfus büyüklüğü nedeniyle sınırlı olan tarım arazilerinin verimli kullanımına ek olarak tarımsal ürünlerin verimli üretimine ihtiyaç duyulmaktadır. Tarımsal ürünlerin verimli üretiminde; ilaçlama, gübreleme ve yabancı ot tespit işlemlerinin yanı sıra bitki hastalıklarının erken aşamada tespit edilmesi kritik öneme sahiptir. Bitkisel hastalıkları nedeniyle tarımsal ürün verimindeki kayıpların %20 ile %40 arasında değiştiği bilinmektedir. Bu ağır verim kaybı, aynı zamanda o ürünün alıcıları için pazar hacminin azalması anlamına da gelmektedir (Savary et al. 2012). Viral, patojenik veya veba kaynaklı bitki hastalıklarının teşhisindeki gecikme, hastalıklı bitkiye daha fazla dozda pestisit uygulanmasını gerektirir ve bu da mahsul kalitesinde düşüşe neden olmaktadır (Ons et al. 2020). Bitki hastalıklarının erken bir aşamada tespit edilmesi ve doğru bir şekilde sınıflandırılması, yalnızca tarımsal ürünlerin kalitesinin iyileştirilmesine katkıda bulunmakla kalmaz, aynı zamanda mantar ilaçları ve herbisitler gibi istenmeyen kimyasal sprey uygulamalarının azaltılmasına da olanak sağlamaktadır (Tewari et al. 2020). Bu çalışmada elma, üzüm ve domates bitkilerindeki hastalıkların gerçek zamanlı erken tespiti için makine öğrenmesi ve derin öğrenme algoritmalarını içeren meta sezgisel optimizasyon destekli öznelik seçimine dayalı sağlam bir melez bitki hastalığı sınıflandırma modeli önerilmektedir. NVIDIA Jetson Nano geliştirici kitine gömülü modelin İnsansız Hava Aracı (İHA) üzerindeki performansı elma, üzüm ve domates bitkileri üzerinde deneysel olarak test edilmektedir.

Dünyada tarım endüstrisindeki ekonomik kayıpların başlıca nedenlerinden biri olan bitki hastalığı, bitkinin normal büyümesini bozan anormal bir durum olarak tanımlanmaktadır (Chadha et al. 2021). Anormal durumla ilgili belirtiler genellikle bitkinin yaprak, gövde ve kök kısımlarında görülmektedir. Yaprak görüntüleri bitki hastalıklarının sınıflandırılmasında iyi bir bilgi kaynağıdır. Bu nedenle araştırmacılar, yaprak görüntüleri aracılığıyla bitki hastalıklarının sınıflandırılmasına odaklanmaktadır (Mohanty et al. 2020). Bu çalışmada elma, üzüm ve domates bitkilerinin yaprak görüntüleri kullanılarak bitki hastalıkları sınıflandırılmıştır.

Küçük ölçekli tarım arazilerinde bitki hastalıklarının tespitinde görsel incelemeye dayalı geleneksel yöntemler kullanılsa da bu yöntemlerin büyük ölçekli tarım arazilerinde uygulanması yorucu ve sürekli izleme gerektirdiğinden oldukça zordur (Zhang et al. 2020). Özellikle benzer yapraklı bitkilerin hem türlerinin hem de hastalıklarının teşhisinde bu süreç daha da zorlaşmakta ve görsel hatalara yol açmaktadır. Bu zorluklarla başa çıkmak için, bitki hastalıklarının bitki yaprak görüntülerine dayalı gerçek zamanlı sınıflandırmasında makine öğrenmesi ve derin öğrenme gibi çeşitli görüntü işleme ve yapay zekâ teknikleri kullanılmaktadır (Barhedo et al. 2016, Barhedo et al. 2018, Almadhor et al. 2021).

Literatürde birçok bitki türü üzerinde bitki hastalıklarının ve hastalık düzeyinin gerçek zamanlı olarak tahmin edilmesine yönelik görüntü işleme tabanlı çalışmalar bulunmaktadır. Tewari et al. (2012), çeltik mahsulünde yaygın olarak görülen beyaz uç hastalığının (*Aphelenchoides besseyi* Christie) şiddet seviyesi görüntü işleme tekniğine dayalı olarak tahmin edilmektedir (Tewari et al. 2012). Çeltik mahsulündeki hastalıklı alan, renk sapmalarına dayalı bir renkli görüntü bölütleme algoritması yardımıyla belirlenmektedir. Belirlenen bölgenin alanı yaprağın tüm alanına oranlanarak hastalığın şiddeti tahmin edilmektedir. Elde edilen tahmin sonuçlarına dayanarak zirai kimyasalların gerçek zamanlı olarak hassas bir şekilde uygulanması için değişken oranlı bir kimyasal püskürtme sistemi geliştirilmiştir. Ali et al. (2017), narenciye bitkilerinin görüntülerindeki hastalıkları sınıflandırmak için bir ΔE (Delta E) bölütleme tabanlı öznelik çıkarma algoritması önermiştir (Ali et al. 2017). Hastalıklı bölge ΔE yöntemi ile tanımlanmakta ve ton doygunluk değeri (Hue Saturation Value-HSV), yerel ikili desenler (Local Binary Patterns-LBP) ve kırmızı yeşil mavi (Red Green Blue-RGB) histogram modelleri bu bölgeden çıkarılmaktadır. HSV, LBP ve RGB tanımlayıcıları ile elde edilen öznelikler birleştirilmekte ve melez bir öznelik seti oluşturulmaktadır. Boyutsallığı azaltmak için temel bileşen analizi (Principle Component Analysis-PCA) kullanılmaktadır. k-En Yakın Komşu (k-Nearest Neighbor-kNN) ve Destek Vektör Makinesi (Support Vector Machine-SVM)

sınıflandırıcıları ile test edilmektedir. SVM sınıflandırıcısı ile en iyi performansın elde edildiği belirtilmektedir. Wen et al. (2019), salatalık yaprağının sağlıklı ve enfekte kısımları arasındaki sıcaklık farkını ölçmüş ve Fourier transform kızılötesi (Fourier Transform Infrared-FTIR) spektroskopisi kullanılarak tüylü küf hastalığı tespit etmiştir (Wen et al. 2019). FTIR tekniğinin salatalık yapraklarında tüylü küf hastalığının ön semptomatik tespitinde etkili olduğu bildirilmektedir. Singh et al. (2017), muz yaprağında erken kavrulma hastalığı, fasulye yaprağında mantar hastalığı, limon yaprağında güneş yanığı hastalığı ve gülde bakteriyel hastalığın tespiti ve sınıflandırılması için öznitelik çıkarma ve bölütleme algoritmaları birlikte kullanmıştır (Singh et al. 2017). Hastalıklı bölgelerin bölütlenmesi genetik algoritma (Genetic Algorithm-GA) kullanılarak gerçekleştirilmektedir. Ayrıca kullanılan optimizasyon algoritmasının hesaplama karmaşıklığını azalttığı da vurgulanmaktadır.

Görüntü işleme yaklaşımında bitki hastalıklarının sınıflandırma doğruluğu, doğrudan öznitelik çıkarma ve bölütleme performansına bağlıdır. Özellikle, görüntü segmentasyonu yaprak hastalığının şiddetinin tespitinde kilit bir rol oynar ve yaprak hastalığının segmentasyon hassasiyeti, hastalık şiddeti sınıflandırmasının doğruluğunu belirlemektedir (Saeed et al. 2021). Görüntü işleme teknikleri bitki yapraklarında hastalık şiddetinin belirlenmesinde iyi sonuçlar vermesine karşın, birden fazla hastalık türünün olduğu bitki yapraklarında hastalık türlerinin sınıflandırılmasında aynı başarıyı sağlamamaktadır. Bunun yerine, görüntü işleme tekniği ile çıkarılan belirli özelliklere ihtiyaç duymadan yinelemeli öğrenme yoluyla daha yüksek tanıma doğruluğuna sahip özellikleri kullanan yapay zekâ temelli yaklaşımlar, son zamanlarda bitki yaprak hastalıklarının sınıflandırılmasında sıklıkla kullanılmaktadır (Ozguven and Altas 2022). Tan et al. (2021), hem derin öğrenme hem de makine öğrenmesi algoritmaları kullanılarak birden fazla domates yaprağı hastalığı türü sınıflandırmıştır (Tan et al. 2021). Makine öğrenimi modellerini uygulamak için, gri seviyeli birlikte oluşum matrisi (Gray Level Co-Occurrence Matrix-GLCM) ve LBP teknikleri kullanılarak toplam 52 doku özelliği, renk histogramı ve renk momenti yaklaşımları kullanılarak 105 renk özelliği çıkarmıştır. Makine öğrenimi algoritmalarından kNN, SVM ve random forest (RF) ve derin öğrenme algoritmalarından AlexNet, VGG16, ResNet34, EfficientNet-b0 ve MobileNetV2 mimarilerinin performansları 10 farklı domates yaprağı hastalığı türü için test edilmiştir. Barbedo (2018), 12 bitki türünü içeren bir dizi görüntü, eğitim ve test bölümlerine ayırmış ve bitki hastalıklarının sınıflandırılması için eğitim verilerinin yardımıyla Evrişimli Sinir Ağı'nı (Convolutional Neural Network- CNN) eğitmiştir (Barbedo 2018). Elde edilen modelin doğruluk performansının her bitki türünün hastalık özelliklerine bağlı olarak %60 ile %100 arasında

değiştirdiği bildirilmektedir. Kamal et al. (2019), sağlıklı ve hastalıklı bitkilerin yaprak görüntülerine dayalı çoklu bitki hastalıklarının verimli bir şekilde sınıflandırılması için MobileNet mimarisinin sadeleşmiş versiyonuna dayanan bir derin öğrenme modeli önermiştir (Kamal et al. 2019). Önerilen model VGG ve klasik MobileNet mimarileri ile karşılaştırılmıştır. Önerilen mimarinin MobileNet'e göre 6 kat, VGG'ye göre ise 29 kat daha az parametre ile %98,34 sınıflandırma doğruluğu sağladığı belirtilmektedir. Modelin hesaplama yükünü azaltmak için farklı optimize edicilerin performansı test edilmektedir. Optimize edicilerinin, stokastik gradyan inişinden (Stochastic Gradient Descent-SGD) daha hızlı yakınsadığı ve hesaplama maliyetinin azaltılmasına katkıda bulunduğu belirtilmektedir. Bu çalışmaların yanı sıra makine öğrenmesi ve derin öğrenme teknikleri gibi yapay zekâ algoritmaları ile birçok bitki türünün yaprak hastalıklarının tanınması ve sınıflandırılması üzerine çok sayıda çalışma bulunmaktadır (Atilla et al. 2021, Li et al. 2020, Thangaraj et al. 2021, Too et al. 2019).

Birden fazla türe ait bitki yaprak hastalıklarının sınıflandırılmasında bahsedilen tekniklerin sınıflandırma doğruluğu yüksek olmasına rağmen, bu tekniklerin yüksek model karmaşıklığı ve yüksek hesaplama maliyetleri, gerçek zamanlı uygulamalarda kullanımlarını zorlaştırmaktadır. Bitki yaprak hastalıklarının gerçek zamanlı sınıflandırma probleminde bu zorlukların üstesinden gelmek için belirli mimarilerle oluşturulmuş yapay zekâ tabanlı modellerin hiper parametrelerinin optimal değerleri, sürü tabanlı optimizasyon algoritmaları kullanılarak belirlenmektedir (Darwish et al. 2020). Son yıllarda bitki yaprak hastalıklarının otomatik teşhis ve sınıflandırmasında sıklıkla kullanılan CNN modelleri, hiper parametre problemini çeşitli meta sezgisel optimizasyon algoritmaları ile çözmeye çalışılmaktadır. Bu, modelin parametre karmaşıklığını azaltmaya katkıda bulursa da modelin hesaplama yükünü artırmaktadır.

Bu tez çalışmasında, Çiçek Tozlaşma Algoritması (Flower Pollination Algorithm-FPA) ile oluşan sarmalayıcı yaklaşımını içeren özellik tabanlı sağlam melez sınıflandırma tekniğini kullanarak bitki yaprak hastalıklarını gerçek zamanlı olarak yüksek doğruluk, düşük parametre karmaşıklığı ve düşük hesaplama maliyeti ile sınıflandırabilen SVM ve CNN sınıflandırıcı ile gerçekleştirilmektedir. Çalışmada, modelin hesaplama yükünün artmaması için sinyal işleme teknikleri ile özellik çıkarımı bir ön işleme adımı olarak ele alınmaktadır. Şimdiye kadar bitki yaprak hastalıklarının sınıflandırılmasında birçok sinyal işleme tekniği ile öznelikler çıkarılmıştır, ancak çeşitli dalgacık ailelerine dayalı İki Boyutlu-Ayrık Dalgacık Dönüşümü (Two-Dimensional Discrete Wavelet Transform-2D-DWT) sinyal işleme tekniği ile öznelik

çıkarmı yapılmamıştır. Bitki yaprak hastalıklarının karakteristik özelliklerini tanımlayan ayırt edici özellikler, Biortogonal, Coiflet, Daubechies, Fejer–Korovkin ve Simlets gibi dalgacık aileleri kullanılarak 2D-DWT tekniği ile ilk kez bu çalışmada çıkarılmıştır. Bu araştırmanın temel katkıları şu şekilde özetlenebilir:

- i)* Bitki yaprak hastalıklarının yüksek doğrulukla gerçek zamanlı sınıflandırılması için 2D-DWT'ye dayalı sağlam bir melez model gerçekleştirilmektedir.
- ii)* Elma, üzüm ve domates bitkilerinden oluşan görüntü veri setine Biorthogonal, Coiflet, Daubechies, Fejer-Korovkin ve Symlets dalgacık aileleri ile 2D-DWT uygulanarak her aile için özellik grupları çıkarılmıştır. Her dalgacık ailesi için çıkarılan özellik grupları, her bir bitki yaprağı hastalığını temsil eden ayırt edici özelliklerden oluşturulmaktadır.
- iii)* Her dalgacık ailesi için sınıflandırıcı performansını yüksek tutan özellikler, popülasyon tabanlı meta sezgisel FPA ve SVM algoritmasından oluşan sarmalayıcı yaklaşımla seçilir. Uygunluk fonksiyonu, model karmaşıklığını ve hesaplama maliyetini minimum seviyede tutmak için hem modelde kullanılan öznelik sayısı hem de model performansı dikkate alınarak hesaplanmaktadır.
- iv)* Önerilen optimizasyon algoritmasının etkinliği, Parçacık Sürü Optimizasyonu (Particle Swarm Optimization-PSO) algoritması ile karşılaştırılarak belirlenmektedir.
- v)* Model hiper parametre probleminin üstesinden gelmek için sınıflandırma performansını yüksek tutabilecek en az sayıda öznelik kullanılarak öznelik çıkarma katmanı olmayan yalnızca bir sınıflandırma katmanına sahip olan CNN sınıflandırıcısı kullanılmaktadır.
- vi)* Gerçek zamanlı bitki yaprak hastalığı sınıflandırma problemi için, 'sym7' dalgacık ailesine dayalı 2D-DWT sinyal işleme yöntemini, FPA ve SVM'den oluşan sarmalayıcı yaklaşımını ve CNN sınıflandırıcıyı içeren en iyi performansa sahip model elde edilmektedir.
- vii)* Elde edilen model, İHA üzerindeki NVIDIA Jetson Nano geliştirici kitine yerleştirilmiştir. Modelin bitki yaprak hastalıklarını gerçek zamanlı olarak yüksek doğrulukla sınıflandırabildiğini göstermek için elma, üzüm ve domates bitkileri üzerinde gerçek zamanlı sınıflandırma testleri yapılmaktadır.

viii) Elde edilen deneysel sonuçlar, modelin düşük hesaplama karmaşıklığına ve minimum hesaplama yüküne sahip olduğunu, bu nedenle yüksek sınıflandırma doğruluğu gerektiren gerçek zamanlı uygulamalarda kullanılabileceğini gösterilmektedir.

Çalışmanın sonraki bölümleri aşağıdaki gibi düzenlenmiştir. Bölüm 2’de tarımsal ortamlarda bitki hastalıkları, hastalığın sebep olduğu kayıplar ve hastalığa müdahale; Bölüm 3’te 2D-DWT, dalgacık aileleri, popülasyon tabanlı meta sezgisel FPA ve SVM algoritmasından oluşan sarmalayıcı yaklaşım, CNN sınıflandırıcı ve sınıflandırma performans ölçütleri dahil olmak üzere bitki yaprak hastalığı sınıflandırma modelini oluşturan tüm metodoloji tanıtılmaktadır. Çalışmanın deneysel sonuçları ayrıntılı tartışmaları ile birlikte Bölüm 4’te sunulmaktadır. Son olarak Bölüm 5’te sonuç açıklamaları özetlenmekte ve araştırma için gelecekteki çalışmalara işaret edilmektedir.

BÖLÜM 2

TARIMSAL ORTAMLARDA BİTKİ HASTALIKLARI VE HASTALIĞA MÜDAHALE

Bitki yaprak hastalıkları, bitki yetiştirme için ciddi bir tehdit türüdür. Bu hastalıklar, yayılmalarında görülen çeşitli üreme, mantarlar, mikroplar, virüsler ve diğer patojenler tarafından oluşmaktadır. Bitki yaprak hastalıkları, bitki örtüsüne olumsuz sonuç verirken verim kaybına neden olabilir ve tarım ekonomisinde kayıplara yol açmaktadır. Ekonomik kayıpların yanı sıra tarımsal mahsulün hem nitelik hem de nicelik olarak azalmasına neden olmaktadır. Yaprak hastalıklarının erken dönemdeki tespiti, uygun yönetim stratejileri yoluyla hastalıkların kontrolünü kolaylaştırabilmektedir. Bitki hastalıklarını fiziksel olarak taramak son derece zordur. Hızlı, doğru ve ucuz teşhis ile birlikte erken teşhis, bitki patolojisinde, özellikle ortaya çıkan hastalıklarda veya ilk başta görülen hafif semptomlar da müdahale edilmesi ürün verimliliğini arttırmaktadır. Bitkilerde görülen hastalıklar dünya çapında tarım endüstrisinde önemli üretim ve ekonomik kayıplara neden olmaktadır. Bitkilerde ve ağaçlarda sağlığın izlenmesi ve hastalıkların tespiti sürdürülebilir tarım için kritik öneme sahiptir. Ekin sağlığı ve hastalık tespiti ile hastalığa özgü kimyasal uygulamalar olan pestisit ve fungisit uygulamaları uygun yönetim stratejileriyle verimliliği artırabilmektedir.

2.1 BİTKİ HASTALIKLARININ TESPİTİNİN BAŞLAMASI VE MÜDAHALELER

Bitki hastalıklarının tespiti ve hastalığa müdahale tarımın başlangıcına dayanmaktadır. İlk çiftçiler, doğaüstü veya batıl inançlı uygulamaları kullanarak mahsullerine patojen hasarına karşı müdahale etmiştir. Bilimsel bir yaklaşıma dayalı bir bitki hastalığının tespiti ancak modern bitki patolojisinin başlangıcından sonradır. Modern bitki patolojisi, 1767'de Giovanni Targioni Tozzetti tarafından İtalya'daki gıda kıtlığını araştırırken buğday "pası" yani Puccinia graminis'inin keşfiyle kurulmuştur. Patateste geç yanıklık ve üzümde külleme salgınları yeni disipline ilham vermektedir. On dokuzuncu yüzyılın ilk yarısında Filippo Re ve Carlo Berti Pichat, bitki hastalıklarını neden oldukları belirtilere göre sınıflandırmaya başlamışlardır. Bitki hastalıklarıyla koloidal kükürt, bakır tuzları ve kireçle mücadele edilmiştir. Son 80 yılda

görsel hastalık değerlendirmelerinin kabul edilebilir doğruluğu ve kesinliği, genellikle geleneksel hastalık ölçekleri kullanılarak elde edilmiştir. Görsel semptomların tanınması, bitki hastalıklarının teşhisi için esastır. Sebze bitkileri, dünya çapında tarımsal üretimin önemli bir ekonomik bölümünü temsil etmektedir. Günümüzde bitki hastalıklarının hem ekonomik hem de sosyal etkileri devam etmektedir. Gıda ve Tarım Örgütü (Food and Agriculture Organization-FAO) tarafından, hastalıkların, böceklerin ve yabancı otların mahsulün %25'inin bozulmasına neden olduğu tahmin edilmektedir. Örneğin, İtalya'nın tüm nüfusunu beslemeye yetecek kadar pirinç, her yıl pirinç patlaması hastalığı nedeniyle yok olmaktadır (Dean et al. 2005). Soya fasulyesi pası bir mantar hastalığıdır ve önemli bir ekonomik kayba neden olmaktadır. Bu enfeksiyonun sadece %20'sini ortadan kaldırarak çiftçiler yaklaşık 11 milyon dolarlık bir kâr elde edebilmektedir (Roberts et al. 2006). Amerika Birleşik Devletleri'nde bitki patojenlerinden kaynaklanan ürün kayıplarının her yıl yaklaşık 33 milyar dolarla sonuçlandığı tahmin edilmektedir. Bunun yaklaşık %65'i (21 milyar dolar) yerli olmayan bitki patojenlerine bağlanabilmektedir (Pimentel et al. 2005).

Bitki hastalık tespiti ve müdahale için etkili teşhis araçları arayışı, iklim değişikliği ve yoğun küresel ticaret ile ürün verim kaybının önlenmesi aciliyetini vurgulamaktadır. Bitki hastalıkları dünyaya geniş çapta yayılmakta ve tarımda ciddi sorunlara yol açmaktadır. Bu nedenle, gelişimin farklı aşamalarındaki hastalık enfeksiyonlarını yönetmek, hastalığın yayılma riskini en aza indirmek ve yenilerinin girişini önlemek için bitki sağlığının izlenmesinde bitki hastalıklarının erken tespiti giderek daha önemli hale gelmektedir (Anderson et al 2004, Brasier et al. 2008, Miller et al. 2009, Strange et al. 2005).

FAO, farklı kıtalarda ulusal ve bölgesel düzeyde ana gıda ürünlerini (pirinç, buğday, mısır, patates, soya ve pamuk) etkileyen haşereler nedeniyle oluşan bitki hastalıklarının her yıl dünya mahsul üretiminin %20 ile %40'ının kaybolduğunu tahmin etmektedir (Oerke 2006). Mahsul kayıpları, gıda güvenliği olmayan yerlerde, yeniden ortaya çıkan zararlılar ve hastalıklar ile daha yüksek ve gıda fazlası olanlarda daha düşük olan üretim koşullarıyla ilişkilidir (Savary et al. 2019). Gıda Güvenliği Otoritesi (European Food Safety Authority-EFSA) tarafından gerçekleştirilen bitki sağlığı gözetimi için uluslararası önlemler alınmaktadır. Bununla birlikte, dünya çapında patojenik organizmaların yayılmasını tomurcuk halinde engellemek için bitki hastalığı teşhisi sınıflandırılması yönünde yeni teknolojik gelişmelere önem verilmektedir. Farklı bitki hastalıklarının gerçek zamanlı tespiti için hızlı yanıt, heterojenlik ve analiz

karmaşıklığı az olan aynı kullanım kolaylığı karşılayan algoritmaların geliştirilmesi oldukça önemlidir. Bitkilerde zararlıların ve hastalıkların yayılmasını önlemek ve aynı zamanda potansiyel salgınları önlemek için Avrupa Birliği (AB) kuralları uygulanmaktadır. Pestisit ihtiyacını azaltarak, yetiştiriciler ve çiftçiler için dokümantasyonu basitleştirerek ve gözetim, eradikasyon ve çevreleme için mali destek sağlayarak ormanların ve peyzajların korunmasına yönelik koruyucu önlemler getirilmiştir. Ticaretin küreselleşmesiyle ilgili olarak, yönetmelik, bu zararlıların oluşturduğu tehlikeyi çözmek ve bitki sağlığı önlemleri yoluyla riskleri uygun bir düzeye indirmek amaçlanmaktadır. Kilit noktalar, tanımlanacak kriterler, öncelikli zararlılar, ithalat, bitki pasaportları ve bitki sağlığı sertifikaları ile zararlıların karantinaya alınmasıyla ilgilidir.

2.2 BİTKİ HASTALIKLARININ BELİRTİLERİ

Bitki yaprak hastalıkları, bitki yetiştirme için ciddi bir tehdit türü yaygın sorunlardan biridir. Bu hastalıkları, yayılmalarında görülen çeşitli üreme, mantarlar, mikroplar, virüsler ve diğer patojenler tarafından oluşturulmaktadır. Bitkilerde bulaşıcı hastalıkların evreleri şu şekilde sınıflandırılabilir: İnokülasyon, Patojen mikroorganizmanın bitkiye teması sonucu bulaşmasıdır. Penetrasyon, hastalığın bitki dokusu içine girmesidir. Enfeksiyon, hastalanma durumudur. Sporulasyon, patojenin hastalık belirtilerinin etrafında üremesini oluşturmasıdır. Organizmalar arasında birbirine zarar verip hastalık oluşturması zararlı maddelerin sentezi, besin rekabeti, ortam koşullarının değişmesi ve organizmalar arası parazitlik bitkiler arasında hastalığı arttırmaktadır. Bitkilerde hastalanma; hastalığa sebep olan biyotik veya abiyotik etkenler, konukçu bitkinin fizyolojik durumu ve çevredeki parazitlik durumu sebep olmaktadır. Hastalıklı bitkilerde görülen semptomlarından biri olan nekroz, hücre yapısının bozulması sonucu oluşur; ölmüş doku ve organlardır. Bitki hastalıklarının belirtileri ilk olarak yapraklarda ortaya çıkmaktadır. Bu belirtiler lokal lekeler, yanıklık, yaralanmalar, çürüklük, kloroz (sarılma), tümör oluşumu ve biçimsiz şekil değiştirmeler şeklindedir.

2.2.1 Bakteriyel Hastalık Belirtileri

Hastalık, su sıçramış gibi görünen küçük açık yeşil noktalarla tasvir edilmektedir. Yaralar genişler ve kuru ölü noktalar olarak ortaya çıkar; örneğin bakteriyel yaprak lekesi, yapraklar üzerinde daha koyu veya koyu renkli suyla ıslatılmış noktalara sahiptir, bazen sarı bir parlaklıkla, tahminen büyük ölçüde ayırt edilemez. Kuru koşullar altında benekler lekeli bir görünüme sahiptir.

2.2.2 Viral Hastalık Belirtileri

Tüm bitki yaprağı hastalıkları arasında, enfeksiyonlardan kaynaklananlar analiz edilmesi en zor olanlardır. Enfeksiyona bağlı hastalıklar diğer hastalık belirti türlerinden belirgin şekilde ayrışabilecek belirtiler vermemektedir. Yaprak bitleri, yaprak zararlıları, beyaz sinekler ve böcekler viral hastalıkların taşıyıcılarıdır. Yapraklar üzerinde sarı-yeşil çizgiler veya benekler görsel belirtileridir. Yapraklar kırışabilir, buruşabilir ve gelişmesi gerileyebilir.

2.2.3 Mantar Hastalığı Belirtileri

Hastalığın başlangıcında eşmerkezli halkalara sahip küçük koyu renkli noktalar şeklinde görünmektedir. Hastalık ilerledikçe lekeler belirsizleşmeye doğru ilerler sonrasında yaprağın arka tarafında beyaz parazit oluşumu başlamaktadır. Hastalığın müdahale edilmeyip büyümesiyle beraberinde yapraklar sararır ve bitkinin diğer organlarına da hastalık erişip ürün kaybına neden olmaktadır.

2.3 BİTKİ HASTALIKLARININ TESPİT YÖNTEMLERİ

Hastalık tespit teknikleri genel olarak doğrudan ve dolaylı yöntemler olarak sınıflandırılabilir. Doğrudan bitki yaprak hastalığı tespit yöntemlerinde moleküler ve serolojik yöntemler kullanılmaktadır. Dolaylı yöntemlerde direkt olarak patojen tespit ve sınıflandırması yapmak yerine, sıcaklık değişimi, solunum ve ortama salgılanan uçucu organik maddeler, çeşitli optik ve kimyasal yaklaşımlarla hastalıkların tespiti yapılmaktadır. Bitki yaprak hastalıkları, bitki örtüsünde olumsuz sonucu üzerine verim kaybına neden olabilir ve tarımda ekonomik kayıplara

yol açabilir. Bu nedenle, erken korunma ve muhafaza edilmesi önemlidir. Bu tekniklerin mevcudiyetine rağmen, bitki hastalıklarının tespiti için hızlı, hassas ve seçici bir yönteme ihtiyaç vardır. Çizelge 2.1’de hastalık tespitinde kullanılan doğrudan yöntemler ve dolaylı yöntemlerin çeşitlerine yer verilmiştir. Çizelge 2.2’de hastalık tespitinde kullanılan yöntemlerin avantaj ve sınırlamaları hakkında özet niteliğindedir. Kullanılan yöntemlerden bazıları; Polimeraz zincir reaksiyonu (Polymerase Chain Reaction-PCR), floresans yerinde hibridizasyon (Fluorescence In-Situ Hybridization-FISH), enzime bağlı immünosorbent deneyi (Enzyme-Linked Immunosorbent Assay-ELISA), immünofloresans (Immunofluorescence-IF) ve akış sitometrisi (Flow Cytometry-FCM) şeklindedir. Bu tekniklerde kullanılan algılama limiti, koloni oluşturan birim (Colony Forming Unit-CFU) olarak bilinmektedir. Bitki hastalığı tespiti yöntemleri analiz ve teknik çeşitlerine göre alt başlıklarda incelenmiştir.

Çizelge 2.1 Bitki hastalığı tespitinde kullanılan doğrudan yöntem ve dolaylı yöntem çeşitleri.

Hastalık Tespiti	
Doğrudan Yöntemler	Dolaylı Yöntemler
PCR FISH ELISA IF FCM	Gazlı metabolit profil oluşturma Bitki metabolit profil oluşturma Görüntüleme teknikleri Spektroskopik teknikler

Çizelge 2.2 Bitki hastalıklarının ve özelliklerinin tespiti için temel tekniklerin karşılaştırılması. (Fang and Ramasay 2015).

Teknikler	Algılama Limiti (CFU/mL)	Avantajlar	Sınırlamalar
PCR	10^3 - 10^5	Yaygın bir teknoloji, kullanımı kolaylığı	DNA ekstraksiyonuna bağlı olma
FISH	10^3	Yüksek hassasiyete sahip	Otofloresans, foto-ışıldama
ELISA	10^5 - 10^6	Düşük maliyetli, görsel renk değişimi yapılabilme	Bakteriler için düşük hassasiyet
IF	10^3	Yüksek hassasiyet, hedef dağılımı görselleştirilmek için kullanılabilme	Foto-ışıldama bozulması
FCM	10^4	Birden fazla eş zamanlı ölçüm yapılabilme	Yüksek maliyet

2.3.1 Görsel İnceleme

Bitkilerin görsel gözlemi ilk olarak bitkinin büyüdüğü yerde yapılmaktadır. Hastalıklı bitki sağlıklı bir bitki ile karşılaştırılmaktadır. Bitki boyu, rengi, yaprak şekli, yaprak dallardaki

yoğunluk, yaprak çapı, kök sistemindeki değişimler gözlemlenmektedir. Gövdelerde, yapraklarda ve diğer organlarda nekroz veya lekeler varsa sclerotia, sporangiophora veya miselyum büyüteç kullanılarak hastalık teşhis edilmeye çalışılmaktadır. Görsel gözlem yoluyla, bitki örneğinde bulunan işaretlere bağlı olarak bir nematod, mantar, bakteri veya virüsün varlığı tespit edilebilmektedir. Bitki üremesinin belirtileri, ölçüt belirleme için önemli bir gösterge olabilmektedir. Tarımsal alanda uzmanlar tarafından yapılması gereken bu yöntem oldukça zaman alıcıdır ve yanılma payı yüksektir. Tek başına kullanıldığında kesin doğrulukta bir çözüm sunmamaktadır.

2.3.2 Mikroskopik Analiz

Mikroskopik analiz, bitki hastalıklarının yayılmasında patojenlerin ve enfeksiyonun belirlenmesinde kullanılmaktadır. Mikroskop altında, hastalık belirtilerinin oluşmasına neden olan mantarlar, bakteriler veya virüsler gibi mikroorganizmalar tanımlanabilmektedir. Doğru bir teşhis için yüksek hassasiyetli mikroskoplar önemli ve yaygın olarak kullanılan bir araçtır. Görsel gözlemin ardından bitkinin enfekteli kısımları mikroskopik inceleme için laboratuvara getirilmektedir. Bitki materyallerinde hastalık semptomlarının birincil gözlemi için bir stereomikroskop kullanılmaktadır. Bitkinin enfekteli kısımlarını mikroskop altında gözlemleyerek, patojenik mantarların hifleri, mikrosklerozu, konidioforları, konidyumları ve bakteriyel hücre kümelerine bakarak tanısal bir sonuca ulaşmak çoğu zaman mümkündür. Maliyetli ve zaman alıcı bir yöntemdir.

2.3.3 Moleküler Teknikler

Moleküler tekniklerin duyarlılığı, numunede tespit edilebilecek minimum mikroorganizma miktarını ifade etmektedir. Hastalık tespiti için yaygın olarak kullanılan moleküler teknik PCR'dır. Diğer moleküler teknikler arasında FISH ve deoksiribo nükleik asit (Deoxyribonucleic Acid-DNA) mikrodizileri yer almaktadır.

PCR tabanlı hastalık tespitinde, jel elektroforezi yapılmadan önce hastalığa neden olan mikroorganizmanın genetik materyali olan DNA ekstrakte edilir, saflaştırılıp çoğaltılmaktadır. Jel elektroforezinde spesifik bir bandın varlığı, bitki hastalığına neden olan organizmanın varlığını doğrulamaktadır. Farklı tipte immünolojik ve PCR teknikleri, López et al. (2003)

tarafından ifade edilmektedir (López et al. 2003). FISH; virüs, bakteri ve mantar patojenlerinin tespiti için mikroskopi ve bitki örneklerinden önceden elde edilmiş olan hastalığa dair ribonükleik asit (Ribonucleic Acid-RNA) sekanslarının DNA problemleri ile hibridizasyonu ile uygulanan bir yöntem çeşididir. Moleküler tekniklerin sınırlamalarından bazıları, zaman alıcı, emeğin yoğun olması, özellikle bitki hastalığı tespitinde güvenilir ve doğru sonuçlar elde etmek için numune hazırlama sırasında ayrıntılı bir prosedür gerektirmektedir. Ek olarak, bu teknikler, her bir spesifik patojeni saptamak üzere uyarlanması gereken sarf malzemesi reaktiflerine gereksinim duymaktadır. Moleküler teknikler, bitki hastalıklarının varlığını sağlamak için sağlam bir araç olarak kullanılabilir, ancak sürece dahil olan zaman nedeniyle çok sayıda bitki örneğini işlemek için bir ön tarama aracı olarak kullanılmamaktadır.

2.3.4 Serolojik Testler

Serolojik testler, bitki yayılmasında bulunan antikorları veya antijenleri tespit ederek hastalığın teşhisini yapabilmektedir. ELISA gibi serolojik testler, bitki gözlemlerinden alınan örneklerde spesifik patojenlerin yayılmasını belirlemek için yaygın olarak kullanılmaktadır. ELISA tabanlı hastalık tespitinde, bir bitki hastalığı ile ilişkili mikrobiyal protein (antijen), antijene karşı antikor üreten bir hayvana enjekte edilmektedir. Bu antikorlar, hayvanın vücudundan çıkarılır ve bir floresan boya ve enzimlerle antijen tespiti için kullanılmaktadır. Hastalığa neden olan mikroorganizmanın (antijen) mevcudiyetinde, numune renk vermektedir ve böylece belirli bir bitki hastalığının varlığını doğrulamaktadır. IF, mikrobiyolojik örneklerin analizinde kullanılan floresans mikroskopisi temelli optik bir yöntemdir.

2.3.5 Bitki Doku Kültürleri

Bitki doku kültürleri, bitkiden alınan örneklerin laboratuvar ortamında büyütülmesiyle sağlanmaktadır. Bu kültürler, patojenlerin izolasyonunu ve tanısını kolaylaştırarak bitki yaprak hastalıklarının teşhisinde kullanılabilir. Zaman alıcı bir yöntemdir.

2.3.6 Spektroskopik ve Görüntüleme Teknikleri

Spektroskopik ve görüntüleme teknikleri, bitkilerde ve ağaçlarda çeşitli faktörlere bağlı hastalıkları tespit etmek ve sınıflandırmak için kullanılan hastalık izleme yöntemleridir. Bu

yöntemler: floresans görüntüleme, multispektral veya hiperspektral görüntüleme, kızılötesi spektroskopi, floresan spektroskopisi, görünür /çok bantlı spektroskopi ve nükleer manyetik rezonans (nuclear magnetic resonance-NMR) spektroskopisi şeklindedir.

- i) Floresans spektroskopisi;* ilgilenilen nesneden gelen floresansın bir ışık demeti genellikle ultraviyole spektrumları ile uyarıldıktan sonra ölçülen bir yöntemdir. Son yirmi yıldır, lazerle indüklenen floresans, bitkilerde stres düzeylerini ve fizyolojik durumlarını izlemek gibi vejetatif araştırmalar için kullanılmıştır (Belasque et al. 2008).
- ii) Görünür ve kızılötesi spektroskopi;* floresans spektroskopisine benzer şekilde, görünür ve kızılötesi spektroskopi, bitki hastalıklarının tespiti için hızlı, tahribatsız ve uygun maliyetli bir yöntem olarak kullanılmıştır. Çeşitli uygulamalar için kullanılan hızlı gelişen bir teknolojidir.
- iii) Floresans görüntüleme;* bitkilerin ultraviyole uyarımı üzerine mavi-yeşil floresans ve klorofil floresansındaki değişiklik, bitkinin fizyolojik durumunun durumunu sağlanabilmektedir (Belasque et al. 2008). Floresans görüntüleme, floresans görüntülerinin (tek spektrum yerine) bir kamera kullanılarak elde edildiği floresans spektroskopisinin gelişmiş halidir.
- iv) Hiperspektral görüntüleme;* hassas tarımdaki uygulaması için büyük ilgi görmektedir (Okamoto et al 2009). Hiperspektral görüntülemeye, her bir pikselin spektral yansıması, elektromanyetik spektrumdaki bir dizi dalga boyu için elde edilmektedir. Elektromanyetik spektrum bölgesini 350-2500 nm dalga boyu aralığı kullanmaktadır ve üç boyutlu veri toplayabilen bir bir tekniktir. Bitki hastalıklarının sebebi olan biyokimyasal ve biyofiziksel özelliklerdeki farklılık değerlerinin ölçümü aracılığıyla hastalık teşhisi yapmaktadır. Hiperspektral görüntüleme genellikle gıda ürünlerinin kalitesini izlemek için kullanılmaktadır.
- v) Akış sitometrisi (FCM);* lazer tabanlı bir optik yöntemdir. Hücre sayımı ve sınıflandırılma yapmaktadır. Aynı zamanda biyoışaretçi tespiti ve protein mühendisliği çalışmalarında da kullanılmaktadır. Analiz edilen hücrelerin bir sıvı içerisinde akarken tespitine ve tanımlanmasına olanak sağlamaktadır.

2.3.7 Hastalık Tespiti İçin Bitki Uçucu Organik Bileşiklerinin Profili

Bitkiler ve ağaçlar tarafından salınan uçucu organik bileşikler (Volatile Organic Compounds-VOC), atmosferde bulunan toplam VOC emisyonlarının yaklaşık üçte ikisine katkıda bulunmaktadır (Guenther 1997). Bir bitki veya ağacın uçucu metabolik profilini etkileyen çok sayıda faktör vardır. Bitkiler tarafından salınan VOC'ler, nem, sıcaklık, ışık, toprak durumu ve gübreleme gibi çeşitli fiziko-kimyasal faktörlerin yanı sıra bitkinin büyüme ve gelişme aşaması, böcekler ve diğer bitkilerin varlığı gibi biyolojik faktörlere bağlıdır (Vallat et al, 2005, Vuorinen et al. 2007).

- i) **Elektronik burun sistemi;** bir elektronik burun sistemi, bir dizi organik bileşiğe duyarlı olan bir dizi gaz sensöründen oluşmaktadır. Her sensörün belirli hassasiyetleri olduğundan, bir dizi sensörün hassasiyetleri atmosferde bulunan farklı bileşikleri ayırt etmek için kullanılmaktadır. Elektronik burun sistemleri birçok uygulama için kullanılmıştır. Gıda ürünlerindeki mikroorganizmaları tespit etmektedir.
- ii) **GC-MS;** farklı çevresel ve fizyolojik koşullarda bitkiler/ağaçlar tarafından salınan uçucu metabolitlerin niceliksel ve niteliksel analizi için yaygın olarak kullanılan bir tekniktir. Çeşitli gıda ürünlerinde bakteri veya mantar enfeksiyonunun neden olduğu uçucu maddelerdeki değişikliğini değerlendirmek için GC-MS çalışmaları yapılmaktadır.

2.4 BİTKİ HASTALIKLARIYLA MÜCADELE YÖNTEMLERİ

Bitki hastalıklarının oluşumunu ve yayılımını önlemek için çeşitli yöntemler kullanılmaktadır. Bu yöntemlerin kullanımı için erken teşhis önemlidir. Bitki hastalıklarının erken tespit edilebilmesi mücadele yöntemlerinin başarısını arttırmaktadır. Hastalık etmenlerinin yayılmasına engel olmak sanitasyon veya eradikasyon ile sağlanabilmektedir. Sanitasyon, hastalığın başlaması ve bulaşmasına engel olmak için kullanılan yöntemleri kapsamaktadır. Sanitasyon hastalıklı kopan bitki organlarının yok edilmesi, tarımda kullanılan aletlerin hijyenine özen gösterilmesi ve hijyenik tarım uygulamalarının yapılmasıyla örneklendirilebilmektedir. Eradikasyon hastalığa sebep olan etmen konukçunun yok edilmesi veya hastalığın yayılmasının tamamen önüne geçilebilmesi için tarımsal alanda kültür bitkisinin dahi ortadan kaldırılması işlemidir. Bitki hastalığının önlemlere rağmen çözüm bulunamadığı

durumlarda salgın hastalık oluşumunun önüne geçebilmek diğer tarımsal alanların bitki örtüsünü korumak adına eradikasyon yapılabilmektedir. Bitki hastalıklarıyla mücadele yöntemleri aşağıdaki maddelerde sıralanmaktadır.

- i) Kanunsal mücadele;** bitki hastalıkları taşımacılık yoluyla ülke içerisinde veya ülke dışından taşınmasına karantina denir. Karantina tedbirleri kapsamında ülke içinde veya ülke dışına bitki hastalıklarının taşınmasının önüne yasa ve hükümlerle geçilebilmektedir. Sertifikasyon aracılığıyla sağlıklı tohum ve üretim sağlanmaktadır. Aynı zamanda regülasyon ile de hastalığın dağılımının önüne geçilen yasal bir önlemdir.
- ii) Kültürel mücadele;** bitkinin hastalanmasına engel olucu önlemlerdir. Her bitkinin yetişmesinde optimum koşullar vardır. Toprak işleme, gübreleme, ekim nöbeti (münavebe), dikim ve sulama her bitkiye özgün uygun biçimde yapıldığında daha sağlıklı tarımsal ürünler elde edilmektedir. Bu koşullar uygun şekilde sağlanmadığında bitkilerin hastalığa yakalanma ihtimalleri artmaktadır.
- iii) Fiziksel mücadele;** yüksek ve düşük sıcaklık uygulamaları, radyasyon uygulamaları ve elektromanyetik dalga kullanımıyla yapılabilmektedir.
- iv) Biyolojik mücadele;** bitkide hastalık oluşturan etmenlere karşı patojen harici canlılar yardımıyla mücadele edilmesidir. Bir bitkinin patojene karşı dayanıklı olması dikey dayanıklılık veya oligogenik dayanıklılık olarak tanımlanmaktadır. Dayanıklı çeşit elde etmek için seleksiyon, melezleme, mutasyon ve biyoteknolojik yöntemler kullanılmaktadır.
- v) Kimyasal mücadele;** ülkemizde ve dünyada en çok uygulanan mücadele yöntemidir. Kimyasal mücadelenin tercih edilme sebebi sonuçlarını kısa sürede vermesi ve diğer yöntemlere göre uygulama kolaylığından dolayıdır. Tarımda kullanılan kimyasal ilaçlara pestisit adı verilmektedir. Fungusları öldüren pestisitlere fungusit, bakterileri öldüren pestisitlere bakterist, virüsleri öldüren pestisitlere virisit, yabancı otları öldüren pestisitlere herbisit denilmektedir.

2.4.1 Pestisitler ve Zararları

Pestisitler, ürünlere saldıran ve onlara zarar veren zararlıları ve böcekleri öldürmek için kullanılmaktadır. Modern tarımda, pestisitler, tarımsal ortamlarda verimli mahsul üretiminin devamlılığı için önemli bileşenlerden biridir. FAO'ya göre, pestisitler, gıda ve tarım ürünlerinin

üretimi, işlenmesi, depolanması, taşınması veya pazarlanması sırasında bitki hastalığına sebep olan haşere, yabancı ot ve diğer bitki patojenlerine karşı önleme ve kontrol etme amacıyla kullanılan kimyasal madde veya maddeler karışımıdır. Pestisitler bitki sağlığını korumak için tasarlanmıştır; ancak, heterojen kimyasalların varlığından dolayı etki biçimleri genellikle spesifik değildir (Bolognesi 2003). Pestisitler genellikle insanlar da dahil olmak üzere zararlılar dışındaki organizmaları da öldürür veya onlara zarar vermektedir. Farklı pestisit türlerinin uygunsuz ve bilinçsiz kullanımı sebebiyle, çevre ve tarımsal mahsullere bu kimyasal maddelerle bulaşabilmektedir (Sarwar 2015). Pestisitler ekinlere fayda sağlar; ancak çevre üzerinde ciddi bir olumsuz etki de yaratmaktadırlar. Pestisitlerin aşırı kullanımı biyolojik çeşitliliğin yok olmasına neden olabilmektedir. Birçok kuş, suda yaşayan organizma ve hayvan, yaşamlarını sürdürebilmek için zararlı pestisitlerin tehdidi altındadır. Pestisitler, çevrenin sürdürülebilirliği ve küresel istikrar için bir endişe kaynağıdır. Pestisitlerin yanlış kullanımı insan sağlığına zarar verebilmektedir. Pestisitlere ve pestisit kalıntılara kasıtlı veya kasıtsız maruz kalmanın ciddi kanser riski taşıdığı bildirilmektedir. Pestisitlere maruz kalma ayrıca cilt hastalıklarına, görme bozukluğuna, nörolojik fonksiyonda kronik bozulmaya, felce, üreme etkilerine ve nörolojik etkilere neden olabilmektedir. Pestisitlerin sağlık üzerindeki etkileri maruz kalma süresine, bireysel sağlık durumuna ve pestisitlerin kimyasal toksisitesine göre değişmektedir. Gelişmiş ülkelerde pestisitlerin gıda üretimine ve kırsal geçim kaynaklarına ekonomik zarar vermesinden dolayı bilinçsiz pestisit kullanımından caydırmak amacıyla politikacılar tarafından pestisit kullanımına vergilendirme getirilmiştir (Carvalho 2006).

2.5 İNCELENEN BİTKİ YAPRAK HASTALIKLARI

Bu tez çalışmasında elma, domates ve üzüm bitki yaprak hastalıkları incelenmektedir. Bitkilerin hastalıkları aşağıdaki alt başlıklarda semptomlarıyla beraber anlatılmaktadır.

2.5.1 Elma Siyah Çürüklük

Siyah çürüklük, özellikle sıcak, nemli bölgelerdeki elma bahçelerinde ciddi kayıplara neden olabilen bir mantar hastalığıdır. Siyah çürüklük mantarı geniş bir coğrafik alanı kaplar ve elma dışında birçok konakçıya bulaşabilmektedir. Bu konakçıların hastalığın yayılmasında ve gelişmesinde rol almaktadır. Hastalık üç formda ortaya çıkmaktadır: siyah çürüklük yaprak lekesi, meyvenin çürümesi ve ağaç dallarında uzuv kanseri şeklinde görülmektedir. Şiddetli

yaprak lekelenmesi, ağacı zayıflatarak yaprak dökülmesine neden olur, enfekteli meyveler tüketilemez hale gelir, uzuv kanserleri tüm dalları kuşatabilir ve sonunda ağacı öldürebilmektedir. Hastalığın yapraklardaki belirtileri ilk olarak ilkbaharın başlarında, yapraklar açılırken ortaya çıkmaktadır. Yaprakların üst yüzeylerinde küçük, mor benekler olarak görünürler ve dairesel lezyonlarla genişlemektedirler. Lezyonların kenarları mor kalırken, merkezleri ten rengine dönmektedir. Birkaç hafta içinde bu yaprak lekelerinde ikincil genişleme meydana gelmekte ve bu sırada lezyonlar karakteristik bir kurbağa gözü görünümü almaktadır. Bir lezyon yaşlandıkça, orijinal enfeksiyon noktasının etrafında bir dizi halka gelişmektedir. Nadiren, lezyonun merkezinde küçük, siyah eşeysiz mantar meyve gövdeleri büyümektedir. Ağır şekilde enfekte olmuş yaprakların dökümü meydana gelmektedir. Yıllık olarak yaprak dökümü meydana gelirse, ağacın gücü büyük ölçüde azalır ve ağaç strese girmektedir.

2.5.2 Elma Memeli Mantarı

Memeli mantarı, yaşam döngüsünü tamamlamak için genellikle iki veya daha fazla konakçıya ihtiyaç duyan birçok türü içeren bir mantar grubu olan Pucciniaceae ailesinin bir üyesidir. Bu ailenin üyeleri, yaşam döngüsünün bir noktasında çoğunun rengi turuncu veya kırmızımsı olduğu için memeli mantarı olarak bilinmektedir. Birçok memeli mantarı, buğday, soya fasulyesi pası ve beyaz çam dahil olmak üzere mahsul bitkilerinin hastalık etkenleridir. Memeli mantarı tarafından üç ila beş farklı spor türü üretilir, ancak her biri birer basidiospordur. Bu sporlar, birçok yaygın mantarı içeren büyük bir grup olan Basidiomycota ailesinin bulunduğu yer olan basidia adı verilen yapılar üzerinde üretilmektedir. Bu memeli mantarı büyük istilaları elmalarda verimi azaltabilir, meyveyi lekeleyebilir ve ağacın ölümüne yol açabilmektedir. Enfekte elma, çiçek açtıktan hemen sonra yapraklarının üst yüzeyinde ur yerine dairesel sarı lekeler göstermektedir. Memeli mantarıyla mücadele etme yöntemleri, kültürel yöntemler ve kimyasal tedaviler ile enfeksiyon önlenmeye çalışılmaktadır.

2.5.3 Elma Kara Leke

Dünyada elmanın yetiştirildiği her yerde görülmekte ve diğer elma hastalıklarından daha fazla zarara neden olmaktadır. Bununla birlikte hastalık, serin ve yağışlı bahar havasına sahip bölgelerde daha yaygındır. Bu hastalık yapraklarda, çiçeklerde ve meyvenin kendisinde

görülebilen lezyonlara neden olmaktadır. Hem yapraklara hem de meyvelere saldırır. Mantar hastalığı ilk önce yaprakların üst yüzeyinde soluk sarı veya zeytin yeşili lekeler olarak görülmektedir. Enfeksiyona maruz kalan genç yaprakların alt yüzeyinde koyu, kadifemsi lekelerdir. Şiddetli şekilde enfekte olmuş yapraklar ve dokular bükülür ve buruşur, sararır ve yazın başlarında dökülebilmektedir. Bu şekilde art arda iki ila üç yıl yaprak dökümü, ağacı önemli ölçüde zayıflatabilir ve onu diğer hastalıklara, böceklerle ve donma hasarı gibi streslere karşı savunmasız hale getirebilmektedir. Meyve üzerindeki belirtiler yapraklarda bulunanlara benzemektedir. Elma kara leke hastalığının ilk belirtileri, enfekte olan ağacın türüne bağlıdır, ancak genellikle ilk belirtiler, tomurcuklara en yakın yapraklarda zeytin yeşili yuvarlak beneklerle donuklaşan yapraklardır. Bu lekeler olgunlaştıkça büyür ve kahverengi ve mantarimsi bir hal almaktadır. Enfekte olmuş meyve bozulur ve ikincil organizmaların girmesine izin verecek şekilde çatlayabilmektedir. Şiddetli şekilde etkilenen meyveler, özellikle gençken düşebilmektedir. Hastalık gelişimi, genellikle ilkbaharda ve yazın başlarında meydana gelen yağışlı, serin hava ile desteklenmektedir. Mantar sporları rüzgâr, yağmur veya yerden sıçrayan su ile çiçeklere, yapraklara veya meyvelere taşınmaktadır.

2.5.4 Üzüm Siyah Çürüklük

Hastalığa *Guignardia bidwellii* mantarı neden olmaktadır. Mantar, üzümlerin yapraklarını, sürgünlerini, meyvelerini, dallarını, salkımlarını ve salkım saplarını enfekte edebilmektedir. Hastalık mevsimin başlarında kontrol altına alınmazsa, üzüm salkımları üzerindeki etkisi yıkıcı olabilir ve tam mahsul kayıplarına neden olabilmektedir. Sıcak ve nemli hava hastalık gelişimini kolaylaştırmaktadır. Siyah çürüklüğün belirtileri ilk önce yapraklarda küçük sarı lekeler olarak ortaya çıkmaktadır. Büyümüş benekler (lezyonlar) koyu kahverengimsi kırmızı bir sınıra sahiptir ve merkezleri bronzdan koyu kahverengiye kadardır. Enfeksiyon geliştikçe, lezyonda, genellikle lezyonun sınırına yakın bir halka şeklinde küçük siyah noktalar belirir. Bu noktalar, yeni dokuyu enfekte edebilen binlerce spor içeren mantar yapılarıdır. Üzüm meyveleri bezelye büyüklüğünde veya daha büyük olana kadar meyve belirtileri genellikle ortaya çıkmaya başlamaz. Enfekte meyveler koyu kahverengi olur ve yüzeyde çok sayıda siyah piknidia ile kaplanmaktadır. Meyveler sonunda sert, siyah mumyalara dönüşmektedir. En ciddi meyve enfeksiyonları, üzüm bezelye büyüklüğünde veya daha büyük olduğunda ortaya çıkmaktadır. Mantarın sporları hastalıklı meyvede üretilir ve bahar yağmurları sırasında yapraklara, çiçeklere ve genç meyvelere bulaşmaktadır. Meyve

enfeksiyonları, çiçeklenme ortasından meyveler renklenmeye başlayana kadar meydana gelir. Olgun yapraklar ve olgun meyveler hassas değildir. Siyah çürüklük enfeksiyonları, sıcaklığa ve yaprakların ıslak kalma süresinin uzunluğuna bağlıdır. Sıcaklığa bağlı olarak duyarlı doku yeterli bir süre boyunca ıslak kalırsa enfeksiyonlar meydana gelmektedir.

2.5.5 Üzüm Siyah Kızamık

Yaygın mantar hastalıklarından biri olan ve yaprağın herhangi bir yerinde kahverengi çizgili lezyonlar olarak kolayca tanımlanabilen siyah kızamık hastalığıdır. Etkilenen yapraklar tamamen kuruyabilir ve bitkiden erken düşebilir, bu da sonunda bitkinin ölümüyle sonuçlanır. *Phaeomoniella spp infestans*'ın neden olduğu üzüm kara kızamık hastalığı, insanoğlunun bildiği en eski bitki hastalıkları arasındadır (Bruno and Sparapano 2007). Yapraklardaki semptomlar, genellikle uygun koşullar altında sürgünlerin uzak kısımlarına doğru hızla dışa doğru yayılan, damarlar arasında veya yaprak kenarları boyunca yuvarlak ve düzensiz lekelerdir. Başlangıçta küçük ve lamina üzerine dağılmış olan noktalar, yavaş yavaş genişler ve yapraklar üzerinde koyu sarı-kahverengi veya kırmızı-kahverengi lekeler oluşmaktadır. Çok az sayıda hastalıklı yaprak, mantar enfeksiyonunu tüm bitkiye yayabilir ve tüm tarlada salgına neden olabilmektedir. Bu nedenle, üzüm hastalığı tehlike bilgilerinin erken bir aşamada elde edilmesi gerçekten gereklidir ve böylece tarım üreticileri, hedeflenen önleme ve kontrol stratejilerini formüle etmek, tarlada bilimsel ve sistematik yönetimi benimsemek, ekonomik kayıpları en aza indirmek için gerçek zamanlı izleme ve takip yapabilmesi hedeflenmektedir. Üzüm siyah kızamık hastalığının doğru tespiti ve değerlendirilmesi, yalnızca bitki sağlığı ve salgın araştırmalarında değil, aynı zamanda üreme, germ plazmasının değerlendirilmesi ve genetik dayanıklılık çalışmaları için de kritik öneme sahiptir.

2.5.6 Üzüm Yaprak Yanıklığı

Üzüm yaprak yanıklığı hastalığı, ticari açıdan önemli çeşitleri etkileyen ciddi, kronik ve sistemik bir üzüm yaprak hastalığıdır. Hastalığa, enfekteli bitkilerin vasküler dokularında yaşayan *Xylophilus ampelinus* bakterisi neden olmaktadır. Duyarlı çeşitlerin şiddetli enfeksiyonu, üzüm sağlığında ciddi bir azalmaya ve büyük hasat kayıplarına yol açmaktadır. Bakteriyel sebeple gelişen yaprak yanıklığı hastalığı yaprak, yaprak sapı, gövde, kök, sürgün veya çiçekleri etkileyebilmektedir. Sürgünde beliren ve yukarı doğru genişleyen, koyulaşan,

çatlayan ve kansere dönüşen doğrusal kırmızımsı kahverengi çizgiler önemli hastalık belirtileridir. Sürgünler daha sonra solgunlaşır, sarkar sonucunda kurur ve genç sürgünlerde en alt boğum aralarında soluk sarı-yeşil lekeler oluşabilmektedir. Olgunluğa erişmemiş çiçekler kararır ve ölürler, kökler de saldırıya uğrayarak sürgün büyümesinin gecikmesine neden olabilmektedir. Renk solması çok genç sürgünlerde daha az görülür, ancak sürgünün tamamı ölmektedir. Üzüm yaprağı hastalıklarının zamanında teşhisi ve doğru teşhisi, hastalığın yayılmasını kontrol altına almak ve üzüm endüstrisinin sağlıklı gelişimini sağlamak için belirleyicidir.

2.5.7 Domates Bakteriyel Benek

Domateste bakteriyel benek hastalığı, yapraklar, gövdeler ve meyveler dahil olmak üzere bir domates bitkisinin tüm toprak üstü kısımlarını etkilemektedir. Yağışlı hava koşullarında, hastalık erken yaprak dökümüne ve meyve lekelenmesine neden olabilir, bu da verimin düşmesine ve domatesin pazarlanamaz hale gelmesine neden olmaktadır. Fidelerde ve olgun bitkilerde bakteriyel benek gelişmektedir. Fidelerde enfeksiyonlar ciddi yaprak dökümüne neden olmaktadır. Daha yaşlı bitkilerde, enfeksiyonlar öncelikle yaşlı yapraklarda meydana gelir ve suyla ıslanmış görünümünde çürümüş alanlar olarak gözlemlenmektedir. Yaprakta oluşan lekeler sarı veya açık yeşilden, siyah veya koyu kahverengiye dönmektedir. Özellikle yaprakların kenarlarında daha büyük yaprak lekeleri de oluşabilmektedir. Olgunlaşmamış meyvelerdeki belirtiler ilk başta küçük bir çürüklük şeklindedir ve kısa süre sonra tüm domates yüzey alanı suyla ıslanmış bir çürüme halinde çevrilidir. Bakteriyel benek, bir mevsimden diğerine ekin artıklarında ve yabani ot konukçularında varlığını sürdürmektedir. Bakteri tohum kaynaklıdır, tohum içinde ve tohum yüzeyinde oluşabilmektedir. Bakteriyel leke patojen, tohumla veya nakillerle yayılmaktadır. Enfeksiyon, bitki üzerindeki yüksek bağıl nem ve serbest nem tarafından desteklenmektedir. Rüzgarla yönlendirilen yağmur, patojenler sıçrayıp sağlıklı yaprak ve meyvelere yayıldığı için daha ciddi hastalıklara katkıda bulunabilmektedir. Bakteriyel leke patojenleri, domates artıklarında iyi bir şekilde hayatta kalabilirler, ancak döküntülerle ilişkili olmadıklarında toprakta çok zayıf bir şekilde hayatta kalmaktadır. Bakteriler, yapraklara doğal açıklıklardan bulaşır; meyveler birbirine sürtündüğünde veya böcekler tarafından ısırıldığında oluşan yaralar yoluyla enfekte olurlar. Bakterilerin yayılma yolları çeşitlidir; yeni dikimlerde enfekte tohumlar ve önceki mahsulün kalıntılarında yaşayan bakteriler aracılığıyla yayılırlar. Bitkiler arasında yağmur damlasıyla, bitkiyi üstten sulamayla

veya yapraklara toprak sıçradığında da yayılmaktadır. Farklı bahçelerdeki mahsüller arasında da rüzgarla savrulan yağmur veya sulama suyuyla bakteriler yayılabilmektedir. Bu hastalığı kimyasallarla kontrol altına almak zor olduğundan kültürel kontrol önemlidir. Kimyasal aşılama veya ilaçlama ile hastalığı kontrol altına almadan pahalı olmasından ziyade, sağlıklı bitkilere de zarar verdiği için kaçınılmaktadır.

2.5.8 Domates Geç Yanıklık

Geç yanıklık, domates ve patatesin yapraklarını, saplarını, domates meyvesini ve patates yumrularını enfekte eden potansiyel olarak yıkıcı bir hastalıdır. *Phytophthora infestans*, domates geç yanıklığından sorumlu oomycete veya su küfü patojenidir. Patojen en çok 1840'larda bir milyondan fazla insanı öldüren ve bir milyonun daha ülkeyi terk etmesine neden olan İrlanda'daki yıkıcı patates kıtlığına neden olmasıyla bilinmektedir. Domates yapraklarındaki geç yanıklığın ilk belirtileri, genellikle etraflarında daha hafif bir hale veya halka bulunan, düzensiz şekilli, ıslak görünümlü lezyonlardır. Bu lezyonlar tipik olarak bitki örtüsünün üst kısmındaki daha genç, daha etli yapraklarda bulunmaktadır. Yaprakların her iki yanında noktalar görülmektedir. Hastalık ilerledikçe, lezyonlar genişleyerek yaprakların kahverengileşmesine, buruşmasına ve ölmesine neden olmaktadır. Geç yanıklık, gelişimin her aşamasında domates meyvesine saldırabilmektedir. Çürümüş meyveler tipik olarak serttir ve sonunda çikolata kahvesi rengine dönüşen yağlı lekeler bulundurmaktadır. Bu lekeler tüm meyveyi kaplayacak kadar büyüebilmektedir. Hastalık tarlalarda hızla yayılır ve tedavi edilmezse tamamen mahsulün bozulmasına neden olabilmektedir. Domateste geç yanıklığı yönetmeye yönelik stratejiler arasında önceki yılın mahsulünden yeniden tohumlanan domates bitkileri elde etmek, hava akışını artırmak ve nemi azaltmak için bitkiler arasında boşluk bırakmak aynı zamanda enfeksiyonu önlemek etkili fungusitlerin uygulanması yer almaktadır. Domates geç yanıklığının kontrolünde kullanılmak üzere çeşitli fungusitler tescil edilmiştir. Bu mantar öldürücülerin geç yanıklığın en iyi kontrolü için ilk enfeksiyondan önce uygulanması kritik öneme sahiptir.

2.5.9 Domates Sarı Yaprak Kıvrıcıklık Virüsü

Domates sarı yaprak kıvrılması virüsü, domates bitkilerinde meydana gelen bir hastalıktır. Enfekte domates bitkileri başlangıçta bodur, dik veya düzensiz bir büyüme gösterir; büyümenin erken aşamalarında enfekte olan bitkiler ciddi bodurluk sergiler. Bununla birlikte, en tanınan semptomlar yapraklarda görülmektedir. Enfekte bitkilerin yaprakları küçüktür ve yukarı doğru kıvrılır, buruşma ve damarlar arası sararma oluşmaktadır. Aynı zamanda enfekte bitkilerin boğum araları kısalmış ve bodur büyümeyle birlikte bitkiler genellikle çalimsı bir görünüm almaktadır. Hastalık bitkilerde oluşan çiçekler genellikle gelişmez ve çiçekleri dökülmektedir. Meyve üretimi, özellikle bitkiler erken yaşta enfekte olduğunda önemli ölçüde azalır ve ağır şekilde enfekte olmuş bitkilerle tarlalarda %100'lük kayıpların yaşanması gözlemlenen bir durumdur. Domatese en çok zarar veren patojenlerden biridir ve dünyanın birçok tropikal ve subtropikal bölgesinde domates üretimini sınırlamaktadır. Virüsün kısa mesafelere yayılmasının birincil yolu Bemisia beyaz sinek türleridir. Uzun mesafelerde, virüs öncelikle enfekte olmuş bitkilerin, özellikle domates nakillerinin hareketi yoluyla yayılmaktadır. Hastalık semptomlarının ortaya çıkması üç hafta kadar sürebileceğinden, hastalıklı semptomu koyulmayan bitkiler bilinmeden nakledilebilmektedir. Virüs ayrıca domates veya diğer bitkiler (örneğin süs bitkileri) üzerinde beyaz sinekler aracılığıyla veya şiddetli rüzgarlar, kasırgalar veya tropik fırtınalar yoluyla virüsü uzun mesafelere taşıyabilmektedir.



BÖLÜM 3

BİTKİ HASTALIKLARININ TEŞHİSİ VE SINIFLANDIRILMASI

Bu bölümde elma, üzüm ve domates bitkilerinin yaprak hastalıklarını gerçek zamanlı olarak yüksek doğrulukla sınıflandırabilen model yapısı anlatılmaktadır. Önerilen modelde elma, üzüm ve domates bitkilerinden oluşan görüntü veri setine Biorthogonal, Coiflets, Daubechies, Fejer-Korovkin ve Symlets dalgacık aileleri ile 2D-DWT sinyal işleme tekniği uygulanarak her bir aile için özellikler çıkarılmıştır. En yüksek model performansını ve en düşük model karmaşıklığını sağlayan özellikler, FPA ve SVM algoritmalarından oluşan sarmalayıcı yaklaşımla seçilmektedir. Model hiper parametre probleminin üstesinden gelmek için kullanılan CNN sınıflandırıcı, seçilen öznitelikler yardımıyla bitki yaprak hastalıklarını sınıflandırılmaktadır. Modelde kullanılan tüm metodoloji aşağıdaki alt bölümlerde ayrıntılı olarak açıklanmaktadır. Algoritmada kullanılan teknikler alt bölümlerde tanıtılmıştır.

3.1 AYRIK DALGACIK DÖNÜŞÜMÜ

Durağan sinyaller için başarıyla uygulanan Fourier dönüşümü (Fourier Transform-FT), durağan olmayan sinyaller için kullanılamaz. Spektrum zamanla değiştiğinden, FT durağan olmayan sinyaller için doğru spektrumu ortaya çıkarmak için yetersizdir. Durağan olmayan sinyaller kısa süreli Fourier dönüşümü (Short-Term Fourier Transform-STFT) ile yeterince küçük parçalara bölünür ve bu küçük parçalar durağan kabul edilmektedir. Farklı zamanlarda hangi frekans bileşenlerinin bulunduğunu ve zaman geçtikçe nasıl değiştiklerini bilmek için zaman-frekans gösterimi gerekmektedir. Zamanla değişen bir sinyalin sinüzoidal frekansı ve faz içeriği STFT tarafından bulunur ve frekans ile zaman değişimi arasındaki ilişki hareketli bir pencere yardımıyla tanımlanmaktadır. Ancak, bu teknik durağan olmayan sinyalleri incelemek için oldukça karmaşıktır. Dalgacık dönüşümü (Wavelet Transform-WT), değişken boyutlu pencereleme teknikleri ile FT ve STFT'nin bu tür zorluklarının üstesinden gelmek için alternatif bir yaklaşım sunulmaktadır (Zhong and Huang 2010, Li et al. 2020). Bu yaklaşımla yüksek frekanslarda kısa zaman aralıkları ve düşük frekanslarda uzun zaman aralıkları seçilebildiğinde bir sinyale ilişkin frekans ve zaman bilgisi elde edilmektedir. Dalgacık dönüşümü, sinyalleri

farklı frekans bileşenlerine ayıran ve her bileşeni o ölçekteki çözünürlüğü ile inceleyen bir dönüştürme tekniğidir. Dalgacıklar, zaman-frekans analizi için iyi bir araçtır (Kim and Aggarwal 2000).

Eğer $\psi(t)$, Fourier spektrumu olan gerçek değerli bir fonksiyon ise, $\psi(s)$ kabul edilebilirlik kriterini karşılamaktadır. O zaman $\psi(t)$ temel dalgacık olarak adlandırılır ve $\psi(s)$ temel dalgacığın Laplace dönüşümünü ifade etmektedir. Burada C_ψ , kullanılan dalgacık sabiti, Denklem 3.1'de tanımlanmaktadır. Denklem 3.1'de integralin paydasındaki s nedeniyle, Denklem 3.2'nin gerekli olduğuna dikkat edilmektedir:

$$C_\psi = \int_{-\infty}^{+\infty} \frac{|\psi(s)|^2}{|s|} ds < \infty \quad (3.1)$$

$$\psi(0) = 0 \Rightarrow \int_{-\infty}^{+\infty} \psi(t) dt = 0 \quad (3.2)$$

Ayrıca, $\psi(\infty) = 0$ olduğundan, kabul edilebilir bir dalgacığın genlik spektrumunun bir bant geçiren filtrenin transfer fonksiyonuna benzer olduğu görülebilmektedir. $\{\psi_{a,b}(t)\}$ dalgacık temel fonksiyonu kümesi, temel dalgacığın $\psi(t)$ çevrilmesi ve ölçeklenmesiyle, Denklem 3.3 yardımıyla oluşturulmaktadır:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (3.3)$$

$$W(a,b) = \langle x, \psi_{a,b} \rangle = \int_{-\infty}^{+\infty} x(t) \psi_{a,b}^*(t) dt \quad (3.4)$$

$a > 0$ ve b reel sayılardır. a değişkeni belirli bir temel fonksiyonun ölçeğini yansıtırken b , t boyunca ötelenmiş konumunu belirtmektedir. $x(t)$ 'nin dalgacık $\psi(t)$ 'ye göre sürekli dalgacık dönüşümü (Continuous Wavelet Transform-CWT) daha sonra da dalgacık dönüşüm katsayıları, temel fonksiyonların her biri ile dönüştürülmekte olan fonksiyonun iç çarpımı olarak Denklem 3.4'te verilmektedir.

Burada $f(t)$ ters süreklî dalgacık dönüşümü matematiksel olarak Denlem 3.5'te tanımlanmaktadır (Grossmann and Morlet 1984).

$$f(t) = \frac{1}{C_\psi} = \int_0^{+\infty} \int_{-\infty}^{+\infty} W(a, b) \psi_{a,b}(t) db \frac{da}{a^2} \quad (3.5)$$

Ölçekleme ve kaydırma dalgacık parametrelerini ayrıık zamanda m ve n ikili deęişkenleri olarak ele aldığımızda, sinyalin ayrıık dalgacık dönüşümü (Discrete Wavelet Transform-DWT) Denklem 3.6'da tanımlanmaktadır:

$$W(m, n) = \langle x, \psi_{m,n} \rangle = a_0^{-m/2} \sum_k f[k] \psi^* \left(\frac{k - na_0^m b_0}{a_0^m} \right) \quad (3.6)$$

Burada m ve n sırasıyla frekans konumu ve zaman konumunu gösterir. Burada, $a_0 > 1$, $b_0 > 0$, ve $m, n \in Z$, ölçekleme ve öteleme parametreleri sırasıyla a_0^m , $na_0^m b_0$ olarak temsil edilmektedir.

3.2 ÇOKLU ÇÖZÜNÜRLÜK ANALİZİ

Sinyallerin sadece zaman alanı özellikleri deęil, aynı zamanda frekans alanı özellikleri de çıkarılıp sınıflandırılabilir. DWT tabanlı çoklu çözünürlük analizi, görüntü sinyallerinden özellik çıkarma uygulamalarında çok kullanışlıdır. Sinyaldeki gürültü ve eğilim gibi istenmeyen bileşenler, çoklu çözünürlük analiz (Multi Resolution Analysis-MRA) ile ayrılabilir (Mallat 1989).

Sinyallerin hem zaman hem de frekans açısından analizi, ölçekleme ve dalgacık fonksiyonlarının hesaplanmasıyla gerçekleştirilmektedir. Ölçekleme $\{\varphi_{m,n}[k]\}$ ve dalgacık $\{\psi_{m,n}[k]\}$ fonksiyonu sırasıyla Denklem 3.7 ve Denklem 3.8'de verilmektedir:

$$\varphi_{m,n}[k] = 2^{-m/2} \varphi(2^{-m}k - n) \quad (3.7)$$

$$\psi_{m,n}[k] = 2^{-m/2} \psi(2^{-m}k - n) \quad (3.8)$$

Burada $m, n \in Z$, yüksek ölçekli, düşük frekanslı bileşenler, dalgacıkları ve filtre bankalarını köprüleyen $\{\varphi[k]\}$ yaklaşım katsayısına karşılık gelir ve Denklem 3.9'da gösterilmektedir:

$$\varphi[k] = \sum_k f[k]h[k - 2n] \quad (3.9)$$

$h[n]$, ölçekleme fonksiyonuyla ilişkili düşük geçiş filtresine karşılık gelmektedir. Düşük ölçekli yüksek frekans bileşenleri, $\{\psi[k]\}$ ayrıştırma katsayısına karşılık gelir ve Denklem 3.10'da ifade edilmektedir:

$$\psi[k] = \sum_k f[k]g[k - 2n] \quad (3.10)$$

Burada $g[n]$, bu ortogonal filtre bankasındaki tamamlayıcı yüksek geçiş filtresidir. $h[n]$ filtre katsayıları tarafından tanımlanan ölçekleme fonksiyonu, düşük geçişli çıkış olarak da adlandırılan $\{\varphi[k]\}$ yaklaşım katsayılarını sağlamaktadır. Filtre katsayıları $g[n]$ tarafından tanımlanan dalgacık fonksiyonu, ayrıştırma katsayıları $\{\psi[k]\}$ veya alternatif olarak yüksek geçiş çıkışı oluşturur.

3.3 DALGACIK AİLELERİ

DWT'nin yüksek ve alçak geçiren filtre katsayılarının hesaplanmasında kullanılan Biorthogonal, Coiflets, Daubechies, Fejer-Korovkin ve Symlets dalgacık aileleri aşağıdaki alt bölümlerde tanımlanmaktadır.

3.3.1 Biorthogonal Dalgacık

Kayıp momentine dayanmayan biorthogonal dalgacıklar, kompakt destekli simetrik bir yapıya sahiptir. Biorthogonal durumda bir ölçekleme ve dalgacık fonksiyonu yerine, farklı MRA üretebilen iki ölçekleme fonksiyonu $\{\varphi, \tilde{\varphi}\}$ Denklem 3.11 ve Denklem 3.12'de ve buna bağlı olarak iki farklı dalgacık fonksiyonu $\{\psi, \tilde{\psi}\}$ Denklem 3.13 ve Denklem 3.14'de tanımlanmaktadır. Ortogonal dalgacıklar için ölçekleme fonksiyonunun ve ana dalgacığın

özyinelemeli hesaplamaları Keinert (1994) tarafından sunulmaktadır (Keinert 1994). Burada $h_0(k)$, $\tilde{h}_0(k)$, $g_1(k)$, ve $\tilde{g}_1(k)$ ikili filtre katsayılarıdır.

$$\varphi(t) = 2 \sum_k h_0(k) \varphi(2t - k) \quad (3.11)$$

$$\tilde{\varphi}(t) = 2 \sum_k \tilde{h}_0(k) \tilde{\varphi}(2t - k) \quad (3.12)$$

$$\psi(t) = 2 \sum_k g_1(k) \varphi(2t - k) \quad (3.13)$$

$$\tilde{\psi}(t) = 2 \sum_k \tilde{g}_1(k) \tilde{\varphi}(2t - k) \quad (3.14)$$

3.3.2 Coiflet Dalgacık

Ingrid Daubechies tarafından Ronald Coifman'ın önerisiyle tasarlanan Coiflet dalgacık, kaybolma momentleri ve ölçekleme fonksiyonları olan ayrık dalgacıklardır. Coiflet dalgacığının arkasındaki fikir, ilişkili ölçekleme fonksiyonunda sıfıra yaklaşan moment koşullarını belirtmektir. Bu durum aynı zamanda tanımlayıcı özelliklere sahip bir dalgacık filtresinin oluşturulmasına da neden olmaktadır (Monzón et al. 1999). Coiflet dalgacık fonksiyonu sıfıra eşit $2N$ momente sahiptir ve ölçekleme fonksiyonu sıfıra eşit $2N - 1$ momente sahiptir. İki fonksiyonun $6N - 1$ uzunluğunda bir desteği vardır. Daubechies dalgacıklarına göre daha simetriktir. Coiflet dalgacığının genel özelliği, verilen herhangi bir destek genişliği için hem ölçekleme $\{\varphi\}$ hem de dalgacık fonksiyonu $\{\psi\}$ için en yüksek kaybolma momentine sahip olmasıdır. Coiflets dalgacığı için ölçekleme ve dalgacık fonksiyonlarının uzunlukları ($L= 6, 12, 18, 24, 30$) olarak hesaplanmaktadır. Yaklaşım özellikleri aynı zamanda kaybolan dalgacık momentlerinin sayısına da bağlıdır (Daubechies 1992).

Coiflet H filtresi cinsinden tanımlamak yeterlidir. Herhangi bir n tamsayısı için $z^n H(z)$ filtresi H ile aynı MRA'yı ürettiğinden, $k < 0$ için H 'nin $\{h_k\}$ katsayılarının her zaman sıfır olduğu varsayılmaktadır.

$\{h_j\}_{j=0}^{L-1}$ gerçek bir kareleme ayna filtresi H 'nin katsayılarıdır. H 'nin γ kaymasında Coiflet'in M, N momentleri Denklem 3.15, Denklem 3.16 ve Denklem 3.17 aracılığıyla açıklanmaktadır:

$$\sum_{j=0}^{L-1} (-1)^j j^k h_j = 0 \quad \text{for } 0 \leq k < M \quad (3.15)$$

$$\sum_{j=0}^{L-1} j^k h_j = \gamma^k \quad \text{for } 0 \leq k < N \quad (3.16)$$

$$3M > L - 1 \quad \text{and} \quad 3N \geq L - 1 \quad (3.17)$$

Bir Coiflet H aynı zamanda Cohen and Sun (1993), birim çemberin üzerindeki belirli konumlarında H 'nin sıfır olmadığı koşulunu da sağlıyorsa, ilişkili dalgacık ve ölçekleme fonksiyonları sırasıyla M ve $N - 1$ kaybolma momentlerine sahip olmaktadır (Cohen and Sun 1993, Monzón et al. 1999). $H(1) = 1$ Normalizasyonu, $k = 0$ ile Denklem 3.16'ya karşılık gelmektedir.

3.3.3 Daubechies Dalgacık

Daubechies dalgacık, Haar dalgacıklarının frekans alanı özelliklerini iyileştiren bir dalgacık toplamını temsil etmektedir. Bu dalgacıklar, N kaybolan dalgacık momentlerinin sayısını temsil etmek için N ile indekslenmiş bir ortogonal dalgacık ailesidir. Daubechies dalgacığının iki önemli özelliği vardır. İlk olarak, sonlu sayıda sıfır olmayan p_m ölçekleme katsayısına sahiptir. Bu, ölçekleme ve dalgacık fonksiyonlarının kompakt olduğu anlamına gelmektedir.

N -dereceli Daubechies ölçekleme fonksiyonu, $2N$ sıfır olmayan ölçekleme katsayılarına sahiptir ve ölçekleme ve dalgacık fonksiyonlarının destek boyutu genişliği $[0, 2N - 1]$ aralığındadır. N -dereceli Daubechies dalgacığının ikinci özelliği, dalgacıkların ilk $N - 1$ momentlerinin sıfır olmasıdır (Daubechies 1988). Ölçekleme ve dalgacık fonksiyonlarının momentleri sırasıyla Denklem 3.18 ve Denklem 3.19'da tanımlanmaktadır:

$$\int_{-\infty}^{+\infty} \varphi(k) k^j d(k) \quad (3.18)$$

$$\int_{-\infty}^{+\infty} \psi(k) k^j d(k) \quad (3.19)$$

Burada $\varphi(k)$ ölçekleme fonksiyonu ve $\psi(k)$ dalgacık fonksiyonudur. Daubechies dalgacığının momenti Denklem 3.20'de ifade edilir:

$$\int_{-\infty}^{+\infty} \psi_N(k) k^j d(k) = 0 \quad \text{for } j = 0, \dots, N-1 \quad (3.20)$$

$$\varphi(k) = \sqrt{2} \sum_{m^*=0}^{N-1} p_m \varphi(2k - m^*) \quad (3.21)$$

ψ_N dalgacığının ilk N momentinin sıfırlanması, genellikle ψ_N 'nin N sıfırlama momentine sahip olması nedeniyle kısaltılmaktadır. Sıfırlanmış momentler, her N -dereceli Daubechies dalgacık temel fonksiyonunun, N 'den küçük tüm polinomlara ortogonal olduğunu göstermektedir. Daubechies dalgacıkları, sahip oldukları sıfır moment sayısına göre sınıflandırılmaktadır. Ölçekleme ve dalgacık fonksiyonlarının düzgünlüğü, sıfır moment sayısı ile doğru orantılı olarak arttığı Denklem 3.21'de görülmektedir (Daubechies 1990).

Dalgacıklar $\psi(k)$ ölçekleme fonksiyonu cinsinden tanımlanmaktadır. Dalgacık ile ölçekleme fonksiyonu arasındaki ilişki Denklem 3.22'de gösterilmektedir:

$$\psi(k) = \sum_{m^*=0}^{N-1} (-1)^{m^*} r_{N-1-m} \varphi(2k - m^*) \quad (3.22)$$

Burada N derece sırasını temsil eder, m^* yerleştirme parametresini gösterir, p_m ve r_{N-1-m} sırasıyla ölçeklendirme ve dalgacık filtre katsayılarının vektörüdür.

3.3.4 Fejer-Korovkin Dalgacık

Daubechies filtrelerinden daha simetrik fakat daha az düzgün olan Fejer-Korovkin dalgacığının çekirdek fonksiyonu Denklem 3.23, Denklem 3.24 ve Denklem 3.25 yardımıyla hesaplanmaktadır. Özel bir filtre sınıfı, MRA filtreleriyle ilişkili filtre ailesidir. Bir MRA filtresi m_0 , Nielsen tarafından MRA ile ilişkilendirilen ölçeklendirme fonksiyonunu üretmektedir (Nielsen 2001).

$$\hat{\varphi}(\xi) = \prod_{j=1}^{\infty} m_0(2^{-j}\xi) \quad (3.23)$$

Denklem 3.24'ü sağlayan ve 0'da 1 değerini alan bir m_0 filtresinin MRA filtresi olabilmesi için yeterli koşul, m_0 'ın $[-\pi/2, \pi/2]$ üzerinde kaybolmamasıdır.

$$|m_0(\xi)|^2 + |m_0(\xi + \pi)|^2 = 1 \quad (3.24)$$

$$K(\xi) = 1 + \pi \sum_{l=0}^{N-1} (-1)^l (2l+1) a_1 \cos((2l+1)\xi) \quad (3.25)$$

$\{K(\xi)\}$ Çekirdek fonksiyonu şu şekilde ifade edilmektedir. Burada a_1 katsayılar dizisidir ve ξ vektörün indeksidir. Fejer-Korovkin filtreleri $|m_0^n(\xi)|^2$ ile Denklem 3.26'da tanımlanmaktadır. n çift ise m_0^n uzunluğu n 'ye ve n tek ise m_0^n uzunluk $n+1$ 'e sahiptir.

$$|m_0^n(\xi)|^2 = \frac{1}{2\pi} \int_{-\pi/2}^{\pi/2} K(\xi - u) du \quad (3.26)$$

3.3.5 Symlets Dalgacık

Daubechies dalgacık yapısına benzeyen Symlets dalgacıkları, Daubechies tarafından literatüre kazandırılan ortogonal, biorthogonal ve en az asimetric dalgacıklar olarak adlandırılmaktadır (Daubechies 1992). Daubechies dalgacık maksimum faza sahipken Symlets dalgacık minimum

faza sahiptir. Daubechies dalgacıklarından farklı olarak Symlets dalgacık, sıfıra yakın momentlerle düzleştirilmiş bir dalgacık fonksiyonuna sahiptir (Mallat 1999). Symlets, N kaybolma momentli $2N - 1$ destek boyutuna sahip olmalarına rağmen Daubechies'ten daha simetriktir. Farklı filtre uzunlukları için Symlets dalgacık katsayıları Daubechies'da hesaplanmıştır (Daubechies 1992).

3.4 İKİ BOYUTLU AYRIK DALGACIK DÖNÜŞÜMÜ

Girdap alanının belirli bir uygulamasında girdap dinamiklerini basitleştirmek için, girdap alanının sonlu enerjiye sahip olduğu varsayılarak 2D-DWT kullanılır; yani $\int \zeta^2(x)dx < \infty$, φ bir ölçekleme fonksiyonu ve ψ üzerinde $L^2(R)$ ortonormal bir temele denk gelen dalgacık olduğu varsayılmaktadır.

Ayrılabilir, “yönsel olarak duyarlı” İki-Boyutlu (Two-Dimensional-2D) dalgacık fonksiyonu $\psi^H(x, y)$, $\psi^V(x, y)$ ve $\psi^D(x, y)$ şu şekilde tanımlanabilmektedir:

$$\psi^H(x, y) = \psi(x)\varphi(y) \quad (3.27)$$

$$\psi^V(x, y) = \varphi(x)\psi(y) \quad (3.28)$$

$$\psi^D(x, y) = \psi(x)\psi(y) \quad (3.29)$$

Burada, H , V ve D sırasıyla yatay (horizontal), dikey (vertical) ve çapraz (diagonal) yönlere karşılık gelmektedir. Yön duyarlılığı, Denklem 3.27, Denklem 3.28 ve Denklem 3.29 arasındaki ayrılabilirliğin doğal bir sonucudur. Bu tez çalışmasında kullanılan Biorthogonal, Coiflet, Daubechies, Fejer-Korovkin ve Symlets dalgacık aileleri ile 2D-DWT'nin hesaplama karmaşıklığını artırdığı görülmektedir.

$$\varphi_{j,m,n}(x, y) = 2^{j/2}\varphi(2^jx - m, 2^jy - n) \quad (3.30)$$

$$\psi_{j,m,n}^i(x, y) = 2^{j/2}\psi(2^jx - m, 2^jy - n) \quad (3.31)$$

Ayrılabilir ölçekleme fonksiyonu $\varphi(x, y) = \varphi(x)\varphi(y)$ yaklaşıklık uzayıyla ilişkilidir. Ayrılabilir 2D ölçekleme ve frekansa bağlı dalgacık fonksiyonları Gonzalez and Woods (2002) Denklem 3.30 ve Denklem 3.31'de tanımlanmaktadır (Gonzalez and Woods 2002).

Burada i terimi H , V veya D 'den birini belirtmektedir. $f(x, y)$ Fonksiyonu için A ve B boyutlarında 2D-DWT hesaplaması şu şekilde ifade edilmektedir:

$$W_{\varphi}(j_0, m, n) = \frac{1}{\sqrt{MN}} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) \varphi_{j_0, m, n}(x, y) \quad (3.32)$$

$$W_{\psi}^i(j, m, n) = \frac{1}{\sqrt{MN}} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) \psi_{j_0, m, n}^i(x, y) \quad (3.33)$$

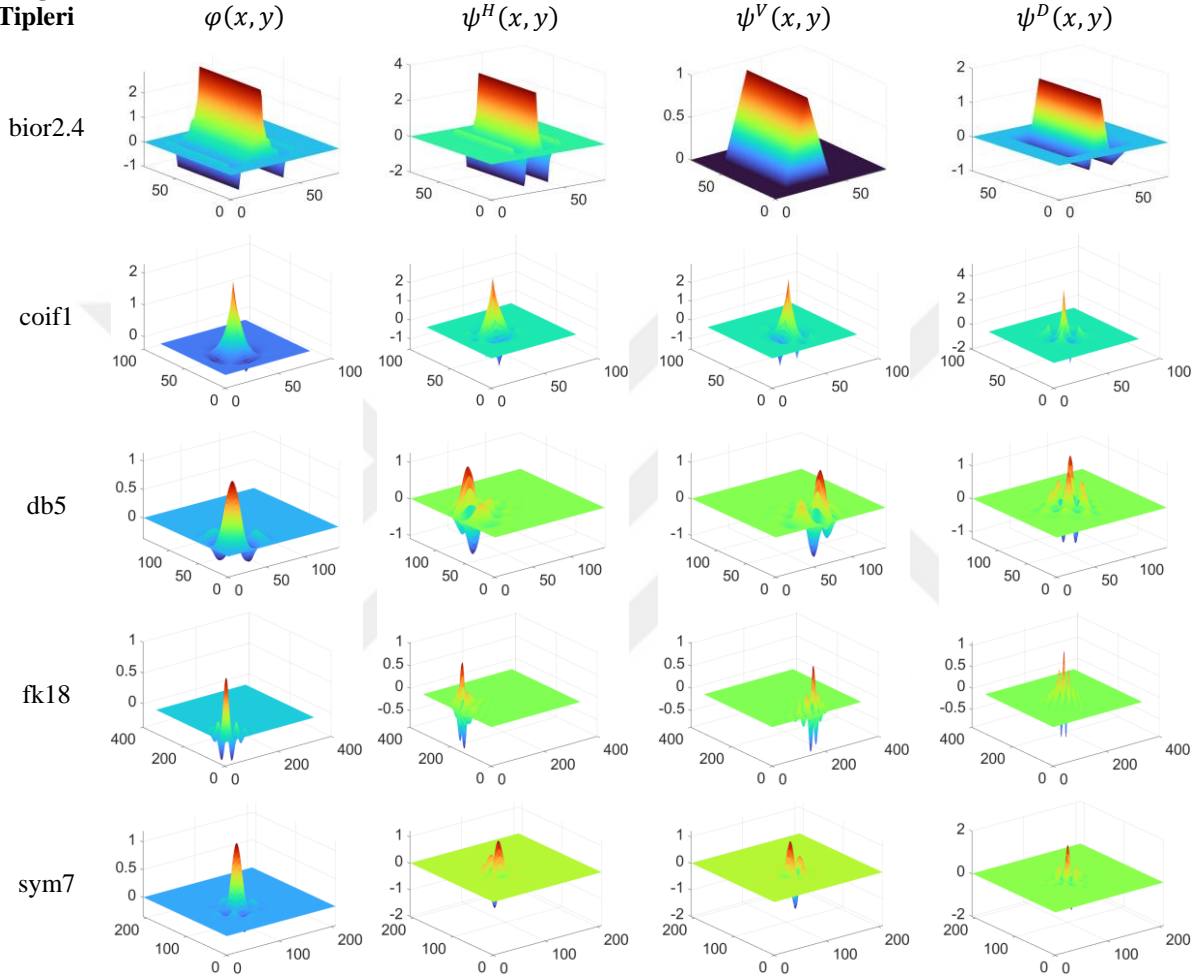
$j = 0, 1, \dots, j-1$ ve $m, n = 0, 1, 2, \dots, 2^{j-1}$ için. j_0 'ın rastgele bir başlangıç ölçeği olduğuna dikkat edilmektedir. Denklem 3.32 ve Denklem 3.33 ile tanımlanan dalgacık dönüşüm katsayılarına sırasıyla yaklaşım ve detay katsayıları denilmektedir. $W_{\varphi}(j_0, m, n)$ katsayıları bu ölçekte $f(x, y)$ 'nin bir yaklaşıklığını tanımlanmaktadır ve $W_{\psi}^i(j, m, n)$ katsayıları $j \geq j_0$ ölçekleri için köşegen, dikey ve yatay ayrıntıları oluşturmaktadır.

Bu tez çalışmasında elma, üzüm ve domates bitkilerinden oluşan görüntü veri setine Biorthogonal, Coiflets, Daubechies, Fejer-Korovkin ve Symlets dalgacık aileleri ile 2D-DWT uygulanmaktadır. Her bir dalgacık ailesi için çeşitli filtre uzunluklarında çıkarılan öznetelik grupları, önerilen bitki yaprak hastalığı sınıflandırma model yapısında kullanılmaktadır. Çalışmada kullanılan tüm dalgacıkların karmaşık sayıların hesaplama karmaşıklığından kaçındığına dikkat edilmelidir.

Her bir dalgacık ailesi için en iyi sınıflandırma performansını sağlayan dalgacıkların ölçekleme fonksiyonu; yatay, dikey ve çapraz dalgacık fonksiyonları Şekil 3.1'de sunulmaktadır. Çalışmada, en iyi sınıflandırma performansını sağlayan dalgacıklar Biorthogonal spline dalgacık ailesi için '**bior2.4**', Coiflets dalgacık ailesi için '**coif1**', Daubechies dalgacık ailesi için '**db5**', Fejer-Korovkin dalgacık ailesi için '**fk18**' ve Symlets dalgacık ailesi için '**sym7**' olarak elde edilmektedir. Ayrıca elma, üzüm ve domatesten oluşan üç bitki türünün her biri için bir

sağlıklı ve üç hastalık sınıfından oluşan on iki sınıfın bulunduğu çalışmada en iyi sınıflandırma performansı 'sym7' ile elde edilen özelliklerle elde edilmiştir. Ölçekleme Fonksiyonu $\varphi(x, y)$ ve $\varphi(x, y) = \varphi(x)\varphi(y)$ tanımlanmaktadır. Yatay Dalgacık $\psi^H(x, y)$, Dikey Dalgacık $\psi^V(x, y)$ ve Diyagonal Dalgacık $\psi^D(x, y)$ şeklinde formüle edilmektedir.

Dalgacık Tipleri



Şekil 3.1 Çalışmada kullanılan her bir dalgacık türü için en iyi sınıflandırma performansını sağlayan dalgacıkların ölçekleme ve ana dalgacık fonksiyonu.

3.5 ÇİÇEK TOZLAŞMA ALGORİTMASI

Yang (2012) tarafından tanıtılan FPA, küresel optimizasyon problemlerinin çözümünde en kısa sürede en iyi sonucu elde etmek için çiçekli bitkilerin üreme sürecinden ilham alan yeni bir meta hiper para meta sezgiseldir (Yang 2012). Kısaca algoritma; polen transfer böcekleri, yarasalar, kuşlar, rüzgâr ve su gibi tozlayıcılar için tüm mekanizmalar dahil olmak üzere bitkilerdeki tozlaşmayı taklit edebilmektedir. Çiçek tozlaşmasının temel amacı, optimum canlılık ve optimum biyolojik üreme evresini sağlamaktır. Tozlaşma ve diğer faktörler, bitkileri

çoğaltmak için en iyi şekilde etkileşime girmektedir. Çiçekler, tozlaşma kurallarını yerine getirmek için tozlayıcılara ihtiyaç duymaktadır. İki tür tozlayıcı vardır. Bunlardan ilki yarasalar, sinekler ve arılar gibi biyotik tozlayıcılardır. Bu tozlayıcılar, çiçeklerin polenlerini çok uzak mesafelere taşıyabilmektedir. Ayrıca bu tozlayıcıların uçuş yolları Lévy dağılımı ile modellenebilmektedir. İkinci tür tozlayıcı, su ve rüzgâr gibi abiyotik tozlayıcılardır. Bu tozlaşma biçiminin kısa mesafelerde gerçekleştiği kabul edilmektedir (Abdel-Basset et al. 2018). Tozlaşma süreci, çapraz tozlaşma ve kendi kendine tozlaşma olmak üzere iki gruba ayrılarak modellenmektedir. Çapraz tozlaşma, farklı bitkilerin çiçeklerinin birbirini tozlaştırması olarak kabul edilmektedir. Kendi kendine tozlaşma, bir bitkinin aynı çiçeklerinin veya farklı çiçeklerinin tozlaşması olarak tanımlanmaktadır. Kendi kendine tozlaşma, yerel arama yönergesi olarak kullanılırken, biyotik çapraz tozlaşma, küresel arama yönergesi olarak adlandırılmaktadır. Kendi kendine tozlaşma sürecinde çiçeklerin birbirine yakınlığı ve rüzgâr gibi etkenler vardır. Bu faktörler nedeniyle yerel arama işlemi genel arama işleminde daha fazla ağırlığa sahiptir. FPA'da kullanılan tozlayıcılar ve tozlaşma türleri Şekil 3.2'de gösterilmiştir. Tozlaşma süreci aşağıdaki dört temel kural kullanılarak taklit edilmektedir:

- i)* Küresel tozlaşma süreçleri biyotik olarak gerçekleştirilir ve tozlayıcılar Lévy uçuşlarına göre çapraz tozlaşma şeklinde polen taşımaktadır.
- ii)* Abiyotik tozlaşma, yerel tozlaşma olarak kendi kendine tozlaşma ve rüzgâr difüzyonu gibi abiyotik koşullarda meydana gelebilmektedir.
- iii)* Çiçek sabitliği adı verilen katsayı, üreme olasılığı olarak ifade edilir ve çiçek türlerinin benzerliği ile orantılı olarak değişmektedir.
- iv)* Küresel tozlaşma ve yerel tozlaşma bir anahtar olasılığı $p \in [0, 1]$ tarafından kontrol edilmektedir. p 'nin optimizasyon arama alanında yerel ve global arama arasındaki yüzde dengesini gösterdiğine dikkat edilmektedir.

Küresel tozlaşmada böcekler uzun süre uçabildikleri için polenler uzun mesafelere taşınmaktadır. Bu durum en iyi üremeyi garanti etmektedir. Küresel tozlaşma ve çiçek sabitliğinin matematiksel ifadesi Denklem 3.34'te tanımlanmaktadır:

$$X_i^{t+1} = X_i^t + L(X_i^t - g_*) \quad (3.34)$$

Burada X_i^t , t yinelemedeki çözüm vektörüdür. g_* , mevcut yinelemedeki tüm çözümler arasında mevcut en iyi çözümdür. i , polen demeti veya çözüm vektörü indeksidir. L , Lévy uçuş dağılımı tozlaşmanın gücünü temsil eden adım boyutudur.



Şekil 3.2 FPA'daki tozlaşma türleri ve tozlayıcılar.

Böcekler ve kuşlar uzun mesafeler boyunca uçarken hareketleri Lévy dağılımına göre gösterilebilmektedir. Tozlayıcılar tarafından alınan uzun mesafeler Lévy uçuşu ile taklit edilmektedir. Lévy uçuş dağılımı Denklem 3.35 yardımıyla tanımlanmaktadır:

$$L \sim \frac{\lambda \Gamma(\lambda) \sin(\frac{\pi\lambda}{2})}{\pi} \frac{1}{s^{1+\lambda}} \quad (s \gg s_0 > 0) \quad (3.35)$$

Burada $\Gamma(\lambda)$, λ indeksli standart gama fonksiyonudur ve Lévy dağılımı $s > 0$ büyük adımlar için geçerlidir. Algoritmadaki abiyotik tozlaşma ve çiçek sabitliği Denklem 3.36'da temsil edilebilmektedir:

$$X_i^{t+1} = X_i^t + \varepsilon(X_j^t - X_k^t) \quad (3.36)$$

Burada X_j^t ve X_k^t aynı bitkinin farklı çiçeklerinin polen demetlerini, yani çözüm kümesinin farklı çözümlerini temsil eder, ε rastgele bir yerel tozlaşma mesafesini belirtir ve $[0, 1]$ arasında normal bir dağılıma sahiptir.

Bu algoritmanın dikkat çekici özelliği, Lévy dağılımı kullanılarak arama uzayında birçok çözüm noktasının aranmasıdır. Global arama ile çözüm uzayındaki çözüm noktalarının belirlenmesi ve yerel arama ile çözüm noktalarının komşuluklarının aranması algoritmanın optimizasyon mantığını oluşturmaktadır.

Çalışmada önerilen FPA ve SVM algoritmasından oluşan sarmalayıcı yaklaşımın hesaplama karmaşıklığı $O(N_*(n \times p_* + fn \times p_*))$ 'dir. Burada N_* yineleme sayısını, n öznitelik sayısını, fn uygunluk fonksiyonu değerini, p_* seçilen özniteliklerin sayısını temsil etmektedir. FPA'nın hızlı yakınsama, düşük karmaşıklık ve iyi optimizasyon performansına sahip olması, SVM'nin düşük hesaplama karmaşıklığına sahip olması ve kolayca tekrarlanabilir olması nedeniyle, bu çalışmada öznitelik seçimi için FPA ve SVM algoritmasından oluşan sarmalayıcı yaklaşımı kullanılmıştır.

3.6 EVRİŞİMLİ SINIR AĞI SINIFLANDIRICISI

Geleneksel sinir ağları, biyolojik sinir sistemlerinin çalışma şekliyle büyük ölçüde ilham alır ve nihai çıktıyı optimize etmek için girdiden toplu olarak öğrenmek adına dağıtılmış bir şekilde çalışan çok sayıda birbirine bağlı hesaplama düğümünden oluşmaktadır. CNN'lerin, öğrenme yoluyla kendi kendini optimize eden nöronlardan oluşmaları bakımından geleneksel sinir ağlarına benzer olduğu bilinmektedir. Başta sınıflandırma olmak üzere birçok bilgisayarlı görme alanında kullanılan CNN'ler, geleneksel sinir ağlarından farklı olarak evrişimli öznitelik çıkarma ve sınıflandırma katmanlarını içermektedir (Gu et al. 2018). Bu tez çalışmasında, model hiper parametre probleminin üstesinden gelmek ve model karmaşıklığını en aza indirmek için öznitelik çıkarma katmanı olmayan tek bir sınıflandırma katmanına sahip CNN sınıflandırıcı kullanılmıştır. CNN'ler; evrişim katmanı, havuz katmanı ve tam bağlantılı katman olmak üzere üç tür katmandan oluşmaktadır. Son evrişim ve havuzlama katmanlarında oluşturulan özellik haritaları, tek boyutlu bir sayı dizisine dönüştürülür ve bir veya daha fazla tamamen bağlı katmana bağlanarak ağın nihai çıktısına eşlenmektedir. Düzleştirilmiş ve tam bağlantılı katmanlardan oluşan iki gizli katmana sahip CNN sınıflandırıcı kullanılmıştır. FPA ve SVM algoritmalarından oluşan sarmalayıcı yaklaşımı ile seçilen öznitelikler, CNN'nin

düzeleştirme katmanına girdi olarak verilmektedir. Böylece modelin hesaplama yükünün artması engellenmiştir.

3.7 SINIFLANDIRMA İÇİN PERFORMANS METRİKLERİ

Tezde kullanılan tüm veri seti, eğitim ve doğrulama aşamaları için sırasıyla %80 ve %20 olmak üzere iki bağımsız veri setine rastgele ayrılmıştır. Bitki yaprak hastalıkları sınıflandırması için çalışmada oluşturulan modellerin eğitim performansı 10 kat çapraz doğrulama yöntemi ile ölçülmüştür. Her sınıflandırma modelinin eğitim performansı, her kat için doğruluk değerlerinin ortalaması alınarak hesaplanmaktadır.

Çalışmada kullanılan tüm sınıflandırma modellerinin performansları Denklem 3.37, Denklem 3.38, Denklem 3.39 ve Denklem 3.40'daki metrikler yardımıyla test verileri üzerinde ölçülmektedir ve verilen metrikler, karışıklık matrisine göre hesaplanmaktadır. Burada TP, FP, TN ve FN sırasıyla gerçek pozitifleri, yanlış pozitifleri, gerçek negatifleri ve yanlış negatifleri ifade etmektedir.

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.37)$$

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (3.38)$$

$$\text{Geri Çağırma} = \frac{TP}{TP + FN} \quad (3.39)$$

$$F1 - \text{skoru} = \frac{2 \times \text{Geri Çağırma} \times \text{Kesinlik}}{\text{Kesinlik} + \text{Geri Çağırma}} \quad (3.40)$$

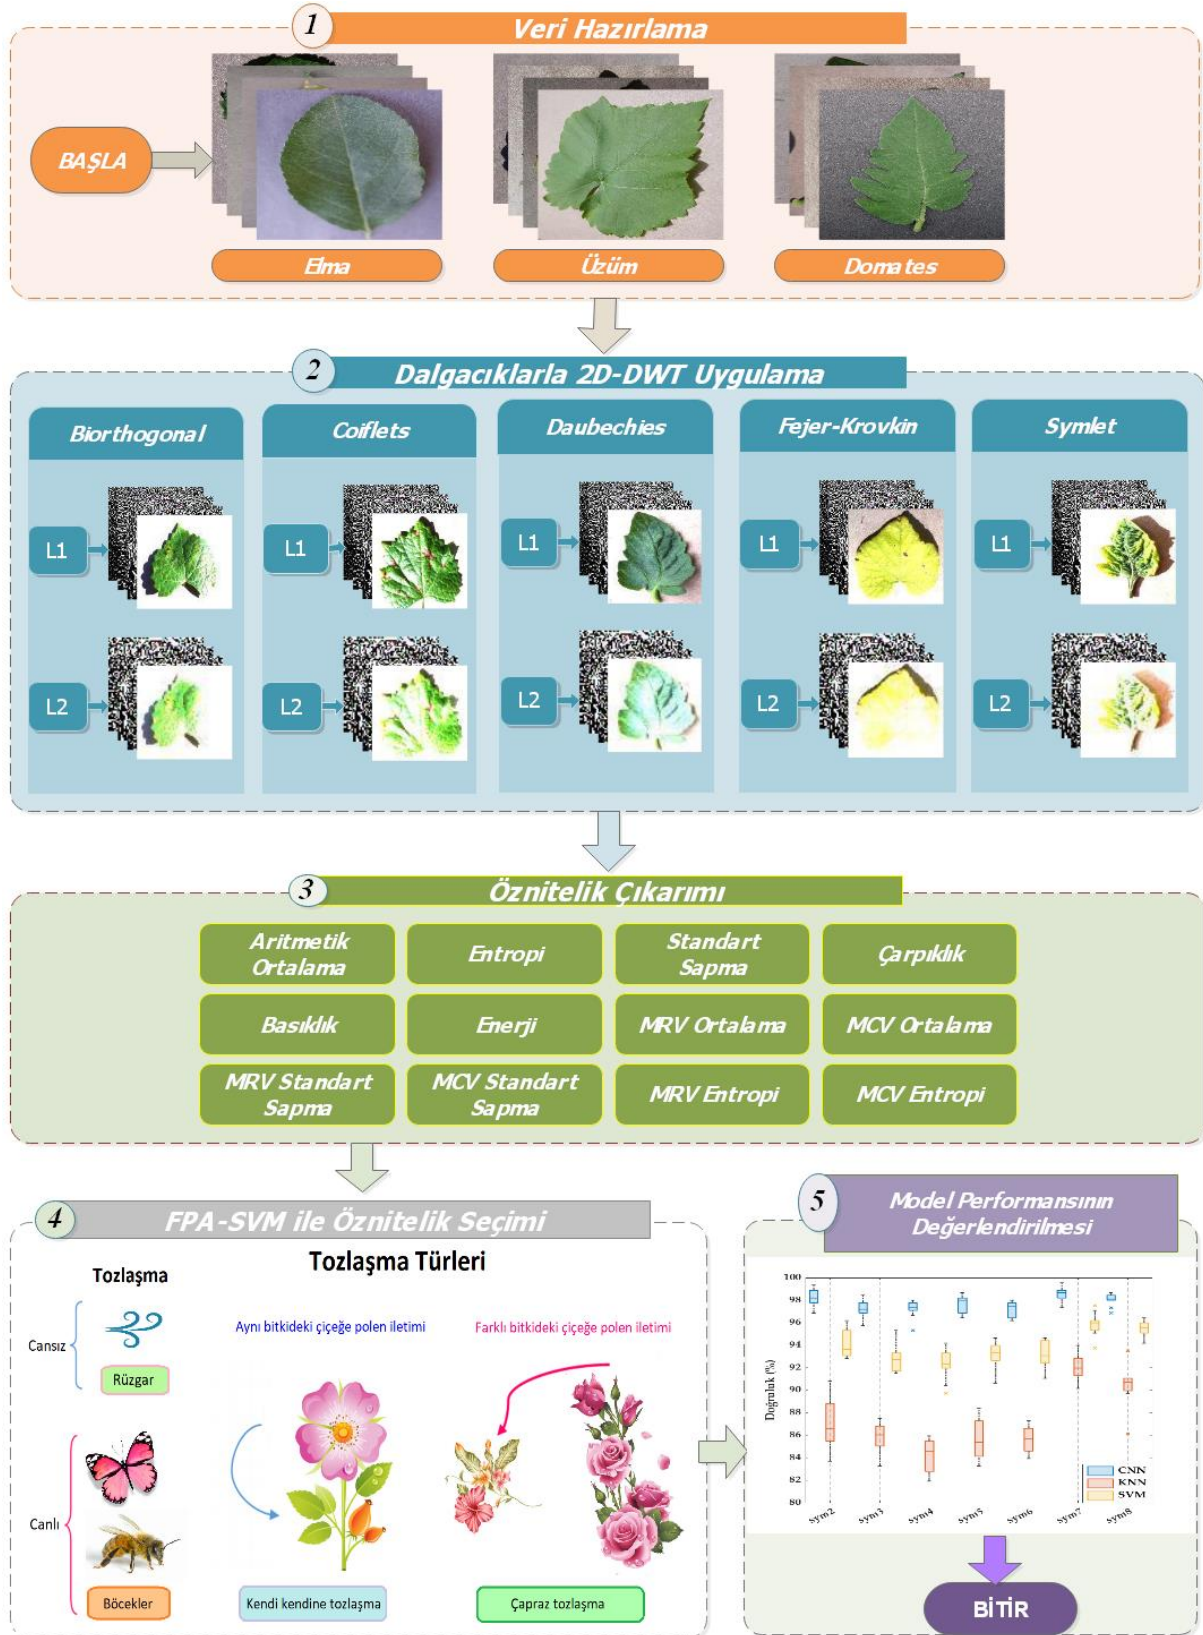
Doğruluk genellikle sınıflandırıcının ne sıklıkla doğru tahmin ettiğinin bir ölçüsüdür. Kesinlik, pozitif olarak tahmin edilen kaç örneğin doğru tahmin edildiğinin oranıdır. Geri Çağırma, pozitif olarak tahmin edilmesi gereken örneklerden kaçının doğru tahmin edildiğinin bir göstergesidir. *F1 – skoru*, hatırlama ve kesinliğin harmonik ortalamasıdır. Sınıflandırıcının ne kadar iyi performans gösterdiğinin bir ölçüsüdür ve genellikle sınıflandırıcıları karşılaştırmak için kullanılmaktadır (Ma et al. 2014).

3.8 BİTKİ YAPRAK HASTALIĞI SINIFLANDIRILMASI İÇİN ÖNERİLEN METODOLOJİNİN ÇERÇEVESİ

Tezde, bitki yaprak hastalıklarını gerçek zamanlı olarak yüksek doğruluk, düşük hesaplama maliyetiyle ile sınıflandırmak için özellikleri 2D-DWT ile çıkarılan ve FPA-SVM sarmalayıcı yaklaşımıyla seçilen CNN sınıflandırıcı ve düşük parametre karmaşıklığı içeren yeni bir sağlam melez model önerilmiştir. Bitki yaprak hastalıklarının gerçek zamanlı sınıflandırması için önerilen yaklaşımın çerçevesi Şekil 3.3'te sunulmaktadır. Önerilen yaklaşımın aşamaları aşağıda kısaca özetlenmiştir:

Veri hazırlama aşamasında elma, üzüm ve domates bitkisi hastalıklarından oluşan görüntü veri seti eğitim ve doğrulama aşamaları için sırasıyla %80 ve %20 olmak üzere iki bağımsız veri setine rastgele ayrılmıştır. 2D-DWT'nin dalgacıklarla uygulanması aşamasında, Biorthogonal, Coiflet, Daubechies, Fejer-Korovkin ve Symlets gibi dalgacık aileleri kullanılarak bitki yaprak hastalıklarının karakteristik özelliklerini tanımlayan ayırt edici özellikler 2D-DWT ile çıkarılmaktadır. Öznitelik çıkarma aşamasında 2D-DWT'nin dikey, yatay, köşegen ve yaklaşık matrislerinden enerji ve istatistik tabanlı öznitelikler çıkarılmaktadır. Bu dört matrise aritmetik ortalama, entropi, standart sapma, çarpıklık, basıklık ve enerji olmak üzere altı özellik uygulanmaktadır. Ayrıca herhangi bir matrisin sütunlarının maksimum değeri olan maksimum sütun vektörü (Maximum Column Vector – MCV) ile ifade edilir ve bunların satırlarının maksimum değeri olan maksimum satır vektörü (Maximum Row Vector – MRV) ile ifade edilmektedir.

Ek olarak, aritmetik ortalama, standart sapma ve hem MCV hem de MRV'nin entropisi olmak üzere altı özellik dört matrise uygulanmaktadır. Aynı süreç, 2D-DWT'deki ikinci ayrıştırma seviyesi için de tekrarlanmaktadır. Bu aşamanın sonunda toplam 96 öznitelik çıkarılmıştır. FPA-SVM ile öznitelik seçimi aşamasında, FPA ve SVM algoritmalarından oluşan sarmalayıcı yaklaşımı yardımıyla her dalgacık ailesi için normalize edilmiş öznitelikler arasından en uygun olanlar seçilmektedir. Ayrıca model karmaşıklığını ve hesaplama maliyetini minimum seviyede tutmak için hem modelde kullanılan öznitelik sayısını hem de model performansını dikkate alan uygunluk fonksiyonu belirlenmektedir. Model performans değerlendirme aşamasında, performans metrikleri yardımıyla CNN, SVM ve KNN sınıflandırıcılarının performansları ölçülür ve performansı en yüksek olan model belirlenmektedir.



Şekil 3.3 Gerçek zamanlı olarak bitki yaprak hastalıklarını sınıflandırmak için önerilen sağlam melez modelin çerçevesi.



BÖLÜM 4

DENEYSEL SONUÇLAR VE TARTIŞMA

Bu bölümde, sağlıklı ve hastalıklı elma, üzüm ve domates bitkilerinin yaprak görüntülerinden oluşan bir veri seti üzerinde bitki yaprak hastalıklarının gerçek zamanlı sınıflandırılması için önerilen melez modelin sınıflandırma etkinliğini gösteren çalışmalar sunulmaktadır. Önerilen model, *sym7* dalgacık ailesine dayalı 2D-DWT sinyal işleme yöntemini, FPA ve SVM'den oluşan sarmalayıcı yaklaşımı ve CNN sınıflandırıcısı içermektedir. Önerilen optimizasyon algoritmasının verimliliği de PSO algoritması ile karşılaştırılmıştır. Melez model için önerilen CNN sınıflandırıcının performansı, SVM ve KNN sınıflandırma algoritmalarının performansları ile karşılaştırılmış ve bitki yaprak hastalığı sınıflandırma modelinin performansına etkisi incelenmiştir.

4.1 VERİ SETİ

Tezde elma, üzüm ve domates bitkilerinin yaprak görüntülerinden oluşan 256×256 piksel boyutunda bir veri seti kullanılmıştır. Çalışmada kullanılan elma, üzüm ve domates bitkisi hastalıklarından oluşan görüntü veri seti, eğitim ve doğrulama aşamaları için sırasıyla %80 ve %20 olmak üzere iki bağımsız veri setine rastgele ayrılmıştır.

Elma bitkisi yaprak görüntülerinden oluşan veri seti Şekil 4.1'de görülen sağlıklı, siyah çürüklük, memeli mantarı ve kara leke hastalığı sınıflarından oluşmaktadır. Her sınıf için resim kullanılmış ve doğrulama aşamasında her sınıftan 55 resim olmak üzere toplam 220 elma bitkisi yaprağı resmi kullanılmıştır.


Üzüm bitkisi yaprak görüntülerinden oluşan veri seti Şekil 4.2'de gösterilen sağlıklı, siyah çürüklük, siyah kızamık ve yaprak yanıklığı hastalık sınıflarından oluşmaktadır. Çalışmadaki modellerin eğitim aşamasında toplam 1680 üzüm bitkisi yaprağı görüntüsü, 420 görüntü her sınıf için kullanılmış ve doğrulama aşamasında, her sınıftan 84 görüntü olmak üzere toplam 336 üzüm bitkisi yaprağı görüntüsü kullanılmıştır.

Domates bitkisi yaprak görüntülerinden oluşan veri seti, Şekil 4.3'de sunulan sağlıklı, bakteriyel benek, geç yanıklık, sarı yaprak kıvrıcılık hastalık sınıflarından oluşmaktadır. Her sınıf için 425 görüntü kullanılmış ve doğrulama aşamasında her sınıftan 85 görüntü olmak üzere toplam 340 domates bitkisi yaprağı görüntüsü kullanılmıştır.


Çalışmada toplam 12 sınıf bulunmakta olup, bu 12 sınıfa ait bitki yaprak görüntüsü sayısı 4480 eğitim verisi ve 896 doğrulama verisi olmak üzere 5376 adettir. Modelin eğitim ve doğrulama aşamalarında kullanılan elma, üzüm ve domates bitkisi yaprak hastalığı görüntüleri, açık kaynaklı Plant Village veri setinden alınmıştır (Mohanty et al. 2016).

Çalışmada kullanılan modellerin test aşaması, İHA üzerindeki kamera yardımı ile elde edilen görüntüler üzerinde gerçekleştirilmiştir. Çalışmada saniyede 30 kare çekim yapabilen GoPro Hero4 kamera kullanılmıştır. İHA ile elde edilen görüntüler 1920 × 1080 çözünürlüğe sahiptir. Bu görüntüler gömülü sistemde yeniden boyutlandırılarak modele 256 × 256 çözünürlükte sunulmuştur. Gimbal sistemi yardımıyla kameranın stabilizasyonu sağlanmıştır. Bulanıklık gibi çevresel koşullarla baş edebilmek için İHA ile çekilen görüntülerde eşik değerler kullanılmıştır. Bu eşik değerleri İHA tarafından alınan görüntünün işlenip işlenmeyeceğine karar verilmiştir.


Modellerin test aşaması, modellerin doğrulama aşamasında kullanılan görüntü sayısı kadar verilerle yapılmıştır. Söz konusu modellerin gerçek zamanlı testleri Ağustos 2022'de Türkiye'nin çeşitli illerinde gerçekleştirilmiştir. Eskişehir'de elma bahçelerinde elma yaprağı hastalık testleri, Manisa'da üzüm bağlarında üzüm yaprağı hastalık testleri ve domates yaprak hastalık testleri yapılmıştır. Antalya ilinde domates tarlalarında yapılmıştır. Testlerin yapıldığı zaman aralıklarında Eskişehir'de ortalama sıcaklık 27 °C, Manisa'da ortalama sıcaklık 30 °C ve Antalya'da ortalama sıcaklık 32 °C idi. Ortalama nem değerleri Eskişehir, Manisa ve Antalya için sırasıyla %62, %73 ve %78 olarak ölçülmüştür. Bazı hastalıkların mevsimselliği göz önünde bulundurularak çalışmadaki testler Türkiye'nin çeşitli illerinde seralar yerine doğal tarım alanlarında gerçekleştirilmiştir.



Şekil 4.1 Elma bitkisinin sağlıklı ve hastalıklı sınıflarına ait yaprak görüntüsü örnekleri.



Şekil 4.2 Üzüm bitkisinin sağlıklı ve hastalıklı sınıflarına ait yaprak görüntüsü örnekleri.



Şekil 4.3 Domates bitkisinin sağlıklı ve hastalıklı sınıflarına ait yaprak görüntüsü örnekleri.

4.2 DALGACIK AİLELERİ İLE 2D-DWT UYGULAMASI

Bitki yaprak hastalıklarının özellikleri, Çizelge 4.1'de gösterilen filtre uzunlukları için Biorthogonal, Coiflets, Daubechies, Fejer-Korovkin ve Symlets dalgacık aileleri kullanılarak 2D-DWT ile çıkarılmaktadır. 256×256 Piksel boyutunda orijinal görüntü matrisine iki seviyeli ayrıştırma uygulanmaktadır. Bu ayrıştırma sonucunda her bir dalgacık ailesi için dikey, yatay, köşegen ve yaklaşım görüntü matrisleri elde edilmektedir. Birinci düzey ayrıştırmada 130×130 piksel boyutunda dört görüntü matrisi ve ikinci düzey ayrıştırmada 67×67 piksel boyutunda dört görüntü matrisi olmak üzere toplam sekiz görüntü matrisi elde edilmektedir.

Çizelge 4.1 Çalışmada kullanılan dalgacık aileleri ve filtre uzunlukları.

Dalgacık Ailesi	Filtre Uzunluğu
Biorthogonal	(1.) 1, 3, 5, (2.) 2, 4, 6, 8, (3.) 1, 3, 5
Coiflet	1, 2, 3, 4, 5
Daubechies	1, 2, 3, 4, 5, 6, 7, 8, 9, 10
Fejer-Korovkin	4, 6, 8, 14, 18, 22
Symlet	2, 3, 4, 5, 6, 7, 8

4.3 İSTATİSTİKSEL VE ENTROPİ TEMELLİ ÖZELLİKLERİN ÇIKARILMASI

Bitki yaprak hastalığı, laboratuvar ortamında yapılan ELISA ve PCR gibi testlerin yanı sıra, bitki bilimci veya çiftçi gibi deneyimli kişiler tarafından yapılan görsel incelemelerle teşhis edilmektedir. Bu doğru bir yaklaşım olmakla birlikte, laboratuvar ekipmanlarının kurulumunu gerektirdiği için maliyetli ve oldukça emek yoğun bir süreçtir. Ancak deneyime ve laboratuvar testlerine dayalı bu geleneksel yöntemler, zaman alıcı oldukları ve ağır iş yükü altında uzmanların hatasına izin verdikleri için bitki yaprak hastalıklarının gerçek zamanlı tespiti için uygun değildir. ELISA ve PCR gibi mikroskopik değerlendirme ve teşhis deneyleri bitki yaprak hastalığının gerçek zamanlı tespitine izin vermediğinden, hastalıkların ayırt edici özellikleri çıkarılmıştır. Çıkarılan özellikler, görsel görüntü analiz teknikleriyle elde edilen özelliklerin aksine, bitki yaprak hastalıklarının karakteristik yapısını tanımlanmaktadır. Çalışmada bitki yaprak hastalıklarını yüksek doğrulukla sınıflandırmak için istatistiksel ve entropi tabanlı özellikler kullanılmıştır. Toplam 96 özellik çıkarılmış ve her özellik Çizelge 4.2'de görüldüğü gibi etiketlenmiştir.

Çizelge 4.2 Görüntü matrislerinden çıkarılan özelliklerin dizin etiketleri.

	I_V^1	I_H^1	I_D^1	I_A^1	I_V^2	I_H^2	I_D^2	I_A^2
F_1	1	13	25	37	49	61	73	85
F_2	2	14	26	38	50	62	74	86
F_3	3	15	27	39	51	63	75	87
F_4	4	16	28	40	52	64	76	88
F_5	5	17	29	41	53	65	77	89
F_6	6	18	30	42	54	66	78	90
F_7	7	19	31	43	55	67	79	91
F_8	8	20	32	44	56	68	80	92
F_9	9	21	33	45	57	69	81	93
F_{10}	10	22	34	46	58	70	82	94
F_{11}	11	23	35	47	59	71	83	95
F_{12}	12	24	36	48	60	72	84	96

Çizelge 4.3'de verilen istatistiksel ve entropi tabanlı özellikler görüntü matrislerine uygulanmaktadır ve $I = \{I_V^1, I_H^1, I_D^1, I_A^1, I_V^2, I_H^2, I_D^2, I_A^2\}$ her bir dalgacık ailesi için birinci ve ikinci seviye ayrıştırmasından elde edilmektedir. Çıkarılan özelliklerin yarısı, $I_j^i(x, y)$ görüntüsünün MRV ve $I_j^i(x, y)$ görüntüsünün MCV'nin ortalama, standart sapma ve entropi değerlerinden

oluşmaktadır. Böylece önerilen bitki yaprak hastalığı sınıflandırma modelinin $I_j^i(x, y)$ görüntü matrisinin satır ve sütunlarındaki değişikliklere duyarlılığı artırılmaktadır (Karasu and Saraç 2022).

Çizelge 4.3 İstatistiksel ve entropi tabanlı özellikler ve denklemleri.

Etiket	Özellik Adı	Özellik İfadesi
F_1	Arithmetik Ortalama	$ortalama = \frac{1}{m \times n} \sum_x \sum_y I_j^i(x, y) $
F_2	Entropi	$entropi = \sum_x \sum_y I_j^i(x, y) \log I_j^i(x, y) $
F_3	Standart Sapma	$std = \sqrt{\frac{1}{m \times n} \sum_x \sum_y (I_j^i(x, y) - ortalama)^2}$
F_4	Çarpıklık	$crpk = \frac{1}{m \times n} \sum_x \sum_y \left(\frac{ I_j^i(x, y) - ortalama}{std} \right)^3$
F_5	Basıklık	$bskl = \frac{1}{m \times n} \sum_x \sum_y \left(\frac{ I_j^i(x, y) - ortalama}{std} \right)^4$
F_6	Enerji	$enerji = \sqrt{\sum_x \sum_y (I_j^i(x, y))^2}$
F_7	MRV ortalama	$MRV_{ortalama} = \frac{1}{m} \sum_x MRV(x)$
F_8	MCV ortalama	$MCV_{ortalama} = \frac{1}{n} \sum_y MCV(y)$
F_9	MRV'nin standart sapması	$MRV_{std} = \sqrt{\frac{1}{m} \sum_x (MRV(x) - MRV_{ortalama})^2}$
F_{10}	MCV'nin standart sapması	$MCV_{std} = \sqrt{\frac{1}{n} \sum_y (MCV(y) - MCV_{ortalama})^2}$
F_{11}	MRV entropi	$MRV_{entropi} = \sum_x MRV(x) \log MRV(x) $
F_{12}	MCV entropi	$MCV_{entropi} = \sum_y MCV(y) \log MCV(y) $

4.4 FPA-SVM YAKLAŞIMI İLE ÖZELLİK SEÇİMİ

Hem sınıflandırma performansının yüksek hem de hesaplama karmaşıklığının minimum düzeyde tutulabilmesi için 2D-DWT tekniği uygulanarak elde edilen sekiz görüntü matrisinden çıkarılan 96 öznelikten en uygun olan alt kümenin belirlenmesi gerekmektedir. Çiçekli bitkilerin üreme sürecini taklit eden FPA, olarak tanımlanan uygunluk fonksiyonu yardımıyla her dalgacık ailesi için normalize edilmiş öznelikler arasından SVM sınıflandırıcı performansını yüksek tutan en uygun öznelikleri seçmektedir.

$$f_{uygunluk} = \mu \times \gamma_R(\varepsilon_C) + \sigma \times \left(\frac{\text{seçilen alt kümenin kardinalitesi}}{\text{toplam özellik sayısı}} \right) \quad (4.1)$$

Burada $\gamma_R(\varepsilon_C)$ sınıflandırıcının sınıflandırma hata oranını gösterir. μ ve σ , sırasıyla sınıflandırma kalitesi ve alt küme uzunluğunun önemini temsil etmektedir. Burada $\mu \in [0,1]$ ve $\sigma = (1 - \mu)$. Uygunluk fonksiyonu, model karmaşıklığını ve hesaplama maliyetini minimum seviyede tutmak için hem modelde kullanılan özelliklerin sayısını hem de model performansını dikkate almaktadır.

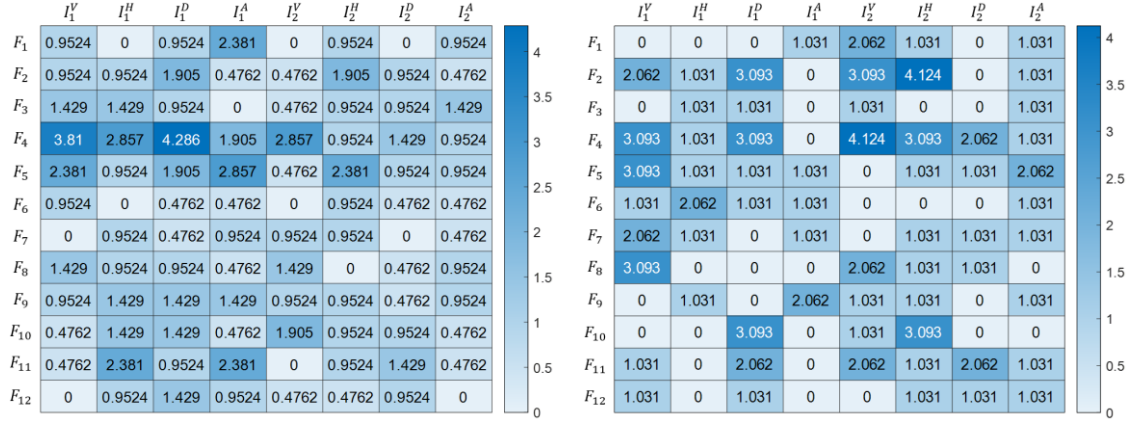
Seçilen öznelik alt kümesi için yüksek performansı ve hızlı yanıt süresi nedeniyle çalışmadaki sarmalayıcı yaklaşım, istatistiksel öğrenme teorisine dayalı SVM algoritması ile oluşturulmaktadır. Sarmalayıcı yaklaşım için önerilen optimizasyon algoritmasının öznelik seçimindeki etkinliği, PSO algoritması ile karşılaştırılarak vurgulanmaktadır. Çalışmada kullanılan FPA-SVM ve PSO-SVM sarmalayıcı yaklaşımlarının parametre değerleri Çizelge 4.4'te sunulmaktadır. Her dalgacık ailesi için oluşturulan modellerde, Çizelge 4.4'teki parametre değerlerine göre özellik seçimi yapıldığına dikkat edilmelidir.

Biorthogonal, Coiflets, Daubechies, Fejer-Korovkin ve Symlets dalgacık ailelerine ait en iyi öznelik grupları için FPA'da 50 iterasyon sonrası toplam seçim oranları Şekil 4.4'deki ısı haritasında yüzde olarak verilmektedir. Biorthogonal için I_H^1 , I_D^1 ve I_A^1 'den, Coiflets için I_V^1 , I_V^2 ve I_H^2 'den, Daubechies için I_V^1 , I_D^1 ve I_A^1 'den öznelikler çıkarılmaktadır, 2D-DWT analizinden elde edilen sekiz görüntü matrisinde Fejer-Korovkin için I_V^1 , I_D^1 ve I_H^2 , ve Symlets için I_V^1 , I_D^1 ve I_H^2 olduğu görülmektedir.

İstatistiksel ve entropi tabanlı özelliklerden biri olan F_4 özelliği tüm dalgacık ailelerinde en az %10 kullanılmaktadır. Bu özelliğe ek olarak Biorthogonal için F_5 , Coiflets için F_2 , Daubechies için F_8 , Fejer-Korovkin için F_5 ve Symletler için F_{11} en az %10 seçilmektedir. Her bir dalgacık ailesi için belirtilen bu iki özelliğin, bitki yaprak hastalığı sınıflandırma modeli için seçilen özelliklerin en az %25'ini oluşturduğu Şekil 4.4'den görülebilmektedir. Öte yandan önerilen bitki yaprak hastalığı sınıflandırma modelinde, Biorthogonal için F_6 ve F_7 , Coiflets için F_1 , F_3 ve F_{12} , Daubechies için F_6 ve F_9 , Fejer-Korovkin için F_6 ve F_{12} özelliklerinin ve en az Symlet için F_1 ve F_6 kullanılmaktadır.

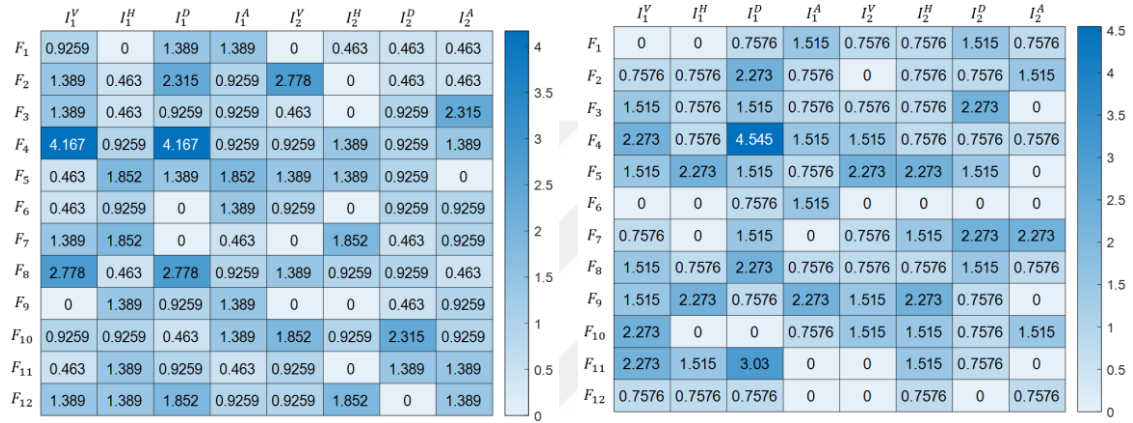
Çizelge 4.4 Çalışmada kullanılan sarmalayıcı özellik seçim yaklaşımlarının parametre değerleri.

Parametreler	FPA-SVM	PSO-SVM
Çözüm sayısı	30	30
Maksimum iterasyon sayısı	50	50
Özellik sayısı	96	96
Eşik değeri	0.7	0.7
Diğer parametreler	<i>değiştirme olasılığı = 0.4</i> <i>vergi bileşeni = 1.5</i>	<i>bilişsel faktör = 2</i> <i>sosyal faktör = 2</i> <i>atalet ağırlığı = 1</i>
Fitness fonksiyonu	sınıflandırıcı performansının maksimize edilmesi & seçilen özelliklerin sayısının en aza indirilmesi	



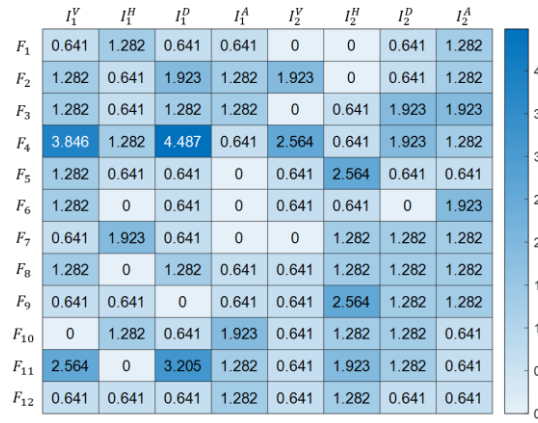
(a)

(b)



(c)

(d)



(e)

Şekil 4.4 a) Biorthogonal, b) Coiflet, c) Daubechies, d) Fejer-Korovkin ve e) Simlet dalgacık aileleri için FPA'nın tüm yinelemelerinin seçilen özelliklerinin ısı haritası.

4.5 BİTKİ YAPRAK HASTALIKLARI SINIFLANDIRMA MODELLERİNİN DEĞERLENDİRİLMESİ VE TARTIŞMA

Bitki yaprağı hastalık görüntüleri çalışmasında bahsedilen tüm modeller, Intel Core i7–10875H işlemci, 8 GB NVIDIA RTX 3070 ekran kartı ve 16 GB RAM'e sahip bir kişisel bilgisayarda gerçekleştirilmektedir. Modellerin tüm kodları MATLAB 2021b tarafından derlenmiştir. Çalışmada oluşturulan modeller, İHA üzerinde kamera ile çekilen 12 bitki yaprak hastalığı sınıfı olmak üzere 896 veri üzerinde test edilmektedir. Oluşturulan tüm modeller 50 kez çalıştırılmış ve modellerin performansı ortalama ve standart sapma olarak hesaplanmaktadır. Çalışmada hem optimizasyon hem de sınıflandırıcı algoritmaların model performansı üzerindeki etkileri incelenmektedir.

Hem FPA-SVM hem de PSO-SVM sarmalayıcı yaklaşımları ile seçilen öznitelikler ile oluşturulan CNN, KNN ve SVM sınıflandırma modellerinin performansları doğruluk metriği açısından ölçülmüş ve sonuçlar sırasıyla Çizelge 4.5 ve Çizelge 4.6'da sunulmaktadır. FPA-SVM sarmalayıcı yaklaşımıyla '*sym7*' dalgacık ailesine dayalı 2D-DWT yöntemiyle oluşturulan özelliklerden 23 özellik alt kümesi seçilmektedir. Seçilen 23 öznitelik ile oluşturulan CNN, SVM ve kNN sınıflandırıcılarının performansları sırasıyla %99.55, %97.54 ve %93.97 olarak ölçülmektedir.

Çalışmada en iyi sınıflandırma performansına sahip model olarak '*sym7*' dalgacık ailesini temel alan 2D-DWT yöntemini, FPA-SVM'den oluşan sarmalayıcı yaklaşımı ve CNN sınıflandırıcısını içeren bitki yaprak hastalığı sınıflandırma modeli önerilmektedir. FPA-SVM'den oluşan sarma yaklaşımı için, SVM ve kNN sınıflandırıcı algoritmaları ile oluşturulan modeller arasında en iyi performans, '*sym7*' dalgacık ailesi tarafından üretilen öznitelikler ile elde edilmektedir. CNN sınıflandırıcının performansı, '*coif2*' ve '*db2*' dışındaki dalgacık aileleri için %95'in üzerinde ölçülmektedir. SVM sınıflandırıcının performansı, '*bior1.1*' ve '*db1*' dışındaki dalgacık aileleri için %90'ın üzerinde ölçülmüştür. kNN sınıflandırıcının performansı '*bior1.1*', '*bior1.3*', '*bior1.5*', '*bior2.8*', '*db1*', '*db2*', '*fk4*' ve '*sym4*' dışındaki dalgacık aileleri için %85'in üzerinde ölçülmüştür. CNN sınıflandırıcının performansının SVM ve kNN sınıflandırıcılarına göre daha üstün olduğu görülmektedir.

Çizelge 4.5 FPA-SVM sarmalayıcı yaklaşımıyla seçilen özellikler için sınıflandırıcıların performansı.

Dalgacık Num.	Seçilen Özellikler	Doğruluk (%)			
		CNN	SVM	KNN	
Biorthogonal (<i>bior</i>)	1.1 24	3, 4, 5, 14, 15, 16, 23, 24, 26, 33, 36, 45, 47, 48, 55, 56, 65, 75, 80, 85, 87, 88, 89, 92	96.90 ± 0.09	89.26 ± 0.36	83.66 ± 0.04
	1.3 23	8, 17, 20, 22, 23, 25, 26, 28, 32, 37, 41, 44, 45, 52, 58, 60, 62, 63, 65, 74, 77, 84, 85	96.76 ± 0.11	91.05 ± 0.02	83.88 ± 0.07
	1.5 26	3, 4, 6, 15, 16, 21, 22, 27, 28, 29, 34, 37, 40, 43, 45, 48, 63, 64, 65, 69, 71, 76, 83, 90, 91, 94	97.68 ± 0.69	91.56 ± 0.63	84.22 ± 0.16
	2.2 17	4, 6, 28, 29, 34, 35, 41, 47, 50, 52, 55, 61, 62, 64, 65, 76, 83	96.45 ± 0.20	92.14 ± 0.27	91.00 ± 0.96
	2.4 21	1, 4, 5, 8, 23, 27, 28, 30, 34, 36, 41, 42, 47, 56, 57, 58, 65, 66, 87, 92, 93	98.08 ± 0.02	93.53 ± 0.33	88.50 ± 0.78
	2.6 19	4, 5, 9, 11, 16, 21, 23, 28, 31, 32, 33, 37, 40, 41, 52, 53, 57, 58, 75	97.34 ± 0.47	93.53 ± 0.11	91.12 ± 0.07
	2.8 21	10, 17, 19, 25, 28, 29, 33, 35, 37, 41, 47, 66, 67, 69, 70, 81, 82, 83, 84, 88, 95	97.50 ± 0.29	92.37 ± 0.07	83.21 ± 0.04
	3.1 20	1, 2, 3, 4, 5, 9, 15, 16, 19, 24, 26, 28, 40, 52, 61, 67, 70, 76, 82, 89	97.34 ± 0.13	92.90 ± 0.07	89.13 ± 0.04
	3.3 19	4, 5, 8, 16, 23, 26, 28, 29, 38, 52, 56, 62, 71, 74, 77, 78, 86, 87, 93	97.34 ± 0.13	93.95 ± 0.80	92.21 ± 0.20
	3.5 20	2, 4, 14, 16, 20, 21, 22, 28, 36, 37, 40, 41, 43, 46, 47, 51, 52, 58, 62, 72	96.90 ± 0.13	93.39 ± 0.13	90.00 ± 0.60
Coiflets (<i>coif</i>)	1 24	4, 5, 8, 11, 14, 15, 16, 19, 28, 34, 35, 49, 50, 52, 58, 61, 62, 64, 68, 70, 84, 85, 89, 91	97.77 ± 0.22	95.29 ± 0.36	89.69 ± 0.07
	2 14	2, 4, 12, 28, 34, 41, 50, 52, 59, 62, 64, 76, 83, 93	93.86 ± 0.11	91.38 ± 0.47	89.87 ± 0.42
	3 18	2, 4, 5, 6, 7, 8, 26, 29, 43, 45, 52, 56, 62, 64, 70, 76, 79, 96	96.32 ± 0.22	92.17 ± 0.54	89.89 ± 0.27
	4 23	7, 8, 17, 18, 21, 26, 28, 34, 35, 37, 42, 45, 49, 56, 57, 62, 65, 67, 80, 86, 88, 90, 95	97.57 ± 0.09	92.63 ± 0.11	85.87 ± 1.27
	5 19	4, 5, 18, 26, 27, 30, 36, 50, 51, 52, 59, 69, 70, 71, 72, 77, 83, 87, 89	97.54 ± 0.11	92.37 ± 0.27	87.30 ± 0.47
Daubechies (<i>db</i>)	1 21	5, 8, 17, 18, 19, 25, 26, 28, 35, 36, 37, 44, 45, 53, 56, 65, 72, 77, 82, 83, 95	94.60 ± 0.51	87.48 ± 0.13	80.71 ± 0.31
	2 22	2, 4, 11, 12, 16, 17, 20, 24, 27, 32, 37, 45, 52, 58, 59, 60, 64, 67, 78, 80, 88, 96	96.70 ± 0.49	91.27 ± 0.02	84.02 ± 0.65
	3 23	3, 4, 7, 15, 19, 21, 25, 28, 35, 39, 42, 50, 51, 52, 53, 67, 68, 75, 78, 80, 81, 93, 96	97.43 ± 0.22	93.04 ± 0.60	85.94 ± 0.11
	4 19	4, 12, 23, 26, 28, 29, 33, 34, 36, 37, 50, 53, 58, 60, 65, 67, 70, 87, 95	97.34 ± 0.09	92.59 ± 0.27	88.44 ± 0.27
	5 21	3, 4, 8, 14, 23, 26, 28, 32, 40, 41, 46, 48, 50, 58, 65, 70, 72, 75, 82, 83, 87	98.19 ± 0.42	94.11 ± 0.58	90.67 ± 0.04
	6 19	2, 4, 10, 21, 26, 28, 32, 38, 39, 41, 46, 47, 64, 72, 76, 82, 83, 91, 93	95.92 ± 0.16	91.38 ± 0.25	89.24 ± 0.60
	7 18	4, 6, 7, 8, 17, 19, 21, 23, 28, 32, 33, 36, 41, 58, 61, 64, 72, 85	95.63 ± 0.20	90.29 ± 0.56	86.05 ± 0.22
	8 27	1, 2, 4, 8, 12, 16, 22, 24, 25, 27, 28, 29, 32, 42, 50, 54, 56, 67, 73, 76, 82, 87, 88, 92, 94, 95, 96	97.88 ± 0.33	93.62 ± 0.02	85.60 ± 0.67
	9 24	3, 4, 7, 8, 10, 22, 28, 29, 32, 40, 41, 43, 45, 48, 50, 54, 56, 59, 74, 79, 87, 90, 91, 94	97.88 ± 0.22	93.93 ± 0.16	86.07 ± 0.20
	10 22	1, 4, 8, 17, 18, 19, 24, 26, 28, 36, 38, 42, 44, 46, 50, 68, 77, 82, 86, 87, 88, 90	97.88 ± 0.11	92.30 ± 0.11	86.41 ± 0.13
Fejer-Krovkin (<i>fk</i>)	4 24	7, 8, 9, 16, 17, 20, 21, 23, 26, 28, 35, 37, 42, 45, 57, 61, 65, 69, 75, 79, 80, 86, 88, 96	96.99 ± 0.22	90.31 ± 0.47	82.19 ± 0.71
	6 20	4, 5, 10, 11, 23, 27, 28, 30, 31, 32, 33, 37, 44, 52, 53, 55, 57, 58, 71, 75	97.52 ± 0.09	93.62 ± 0.13	85.69 ± 0.20
	8 23	3, 4, 8, 11, 21, 28, 32, 35, 38, 39, 40, 42, 45, 56, 67, 72, 73, 77, 81, 83, 91, 92, 94	97.97 ± 0.20	93.21 ± 0.47	86.58 ± 0.02
	14 21	3, 10, 11, 15, 17, 24, 26, 28, 29, 31, 32, 49, 53, 67, 68, 75, 76, 77, 80, 82, 91	97.70 ± 0.04	93.15 ± 0.18	87.17 ± 0.33
	18 23	4, 5, 9, 10, 12, 14, 17, 21, 25, 26, 27, 28, 35, 52, 62, 63, 65, 69, 70, 71, 73, 74, 79	97.99 ± 0.11	94.75 ± 0.11	90.33 ± 0.18
	22 21	2, 28, 29, 35, 36, 40, 41, 45, 46, 51, 53, 58, 64, 65, 69, 70, 79, 85, 86, 91, 94	96.81 ± 0.16	90.96 ± 0.56	86.03 ± 0.31
Symlets (<i>sym</i>)	2 25	2, 4, 11, 13, 17, 22, 24, 28, 29, 35, 38, 64, 65, 69, 71, 72, 75, 76, 79, 80, 81, 87, 90, 92, 93	98.28 ± 0.18	94.13 ± 0.40	87.14 ± 0.13
	3 21	2, 4, 6, 7, 8, 9, 19, 25, 28, 32, 35, 46, 52, 59, 65, 71, 75, 81, 84, 85, 89	97.21 ± 0.11	92.95 ± 0.47	85.83 ± 0.45
	4 20	3, 5, 11, 15, 19, 26, 27, 28, 35, 50, 60, 68, 69, 70, 74, 75, 76, 85, 87, 96	97.21 ± 0.56	92.28 ± 0.31	84.22 ± 0.29
	5 24	3, 4, 6, 11, 12, 14, 19, 26, 28, 31, 32, 39, 46, 48, 52, 47, 65, 66, 67, 83, 86, 88, 90, 91	97.68 ± 0.13	93.24 ± 0.60	85.65 ± 0.18
	6 20	4, 11, 27, 28, 35, 37, 38, 39, 53, 54, 56, 58, 69, 70, 71, 72, 77, 83, 86, 91	97.23 ± 0.13	93.15 ± 0.29	85.71 ± 0.11
	7 23	1, 4, 5, 8, 16, 21, 22, 26, 28, 34, 36, 40, 44, 45, 46, 47, 50, 52, 57, 80, 82, 87, 94	99.55 ± 0.13	97.54 ± 0.25	93.97 ± 0.04

Çizelge 4.6 PSO-SVM sarmalayıcı yaklaşımı ile seçilen özellikler için sınıflandırıcıların performansı.

Dalgacık Num.	Seçilen Özellikler	Doğruluk (%)			
		CNN	SVM	KNN	
Biorthogonal (<i>bior</i>)	1.1 19	5, 11, 19, 26, 28, 29, 32, 40, 41, 45, 56, 62, 63, 64, 70, 75, 85, 87, 96	91.71 ± 0.04	84.93 ± 1.09	80.40 ± 0.36
	1.3 21	3, 4, 5, 9, 11, 14, 15, 19, 21, 25, 27, 39, 46, 62, 63, 74, 76, 77, 84, 91, 93	92.03 ± 0.29	81.96 ± 0.02	74.28 ± 0.18
	1.5 23	3, 5, 8, 9, 10, 26, 28, 29, 31, 34, 37, 40, 41, 49, 56, 59, 62, 66, 79, 81, 87, 91, 92	92.90 ± 0.25	84.64 ± 0.54	78.17 ± 0.02
	2.2 17	1, 2, 4, 16, 26, 27, 28, 52, 53, 65, 69, 70, 78, 85, 86, 87, 96	91.11 ± 0.09	86.85 ± 0.78	85.31 ± 0.20
	2.4 18	3, 4, 5, 6, 17, 24, 26, 27, 28, 36, 40, 47, 53, 69, 76, 79, 80, 87	92.41 ± 0.02	86.42 ± 0.13	85.55 ± 0.04
	2.6 15	4, 16, 44, 47, 50, 52, 57, 60, 69, 70, 73, 76, 80, 81, 89	88.14 ± 0.18	82.34 ± 0.16	79.19 ± 0.63
	2.8 19	12, 16, 23, 28, 35, 41, 42, 43, 45, 51, 59, 66, 67, 72, 73, 76, 79, 90, 96	93.10 ± 0.45	87.32 ± 0.02	81.49 ± 0.22
	3.1 20	1, 9, 12, 14, 15, 16, 20, 24, 28, 29, 31, 32, 34, 57, 63, 77, 87, 88, 92, 94	92.96 ± 0.09	86.42 ± 0.13	82.47 ± 0.20
	3.3 21	1, 2, 6, 12, 13, 29, 35, 37, 40, 44, 52, 53, 57, 62, 64, 67, 70, 77, 83, 86, 89	92.79 ± 0.09	85.29 ± 0.33	78.23 ± 0.47
	3.5 19	2, 5, 7, 12, 14, 16, 28, 31, 38, 42, 51, 60, 66, 67, 72, 79, 83, 89, 92	92.74 ± 0.20	87.16 ± 0.65	83.21 ± 0.27
Coiflets (<i>coif</i>)	1 19	3, 4, 10, 11, 17, 35, 36, 37, 50, 56, 59, 61, 68, 73, 84, 88, 89, 92, 95	92.23 ± 0.09	85.29 ± 0.22	79.71 ± 0.22
	2 22	4, 13, 14, 15, 24, 28, 33, 35, 36, 39, 50, 52, 53, 58, 66, 68, 69, 76, 87, 89, 93, 96	92.94 ± 0.27	87.92 ± 0.18	85.58 ± 0.16
	3 20	1, 4, 6, 7, 13, 19, 21, 26, 28, 29, 45, 46, 52, 63, 68, 71, 76, 79, 82, 90	93.17 ± 0.04	89.44 ± 0.20	85.64 ± 0.02
	4 17	4, 12, 17, 20, 23, 26, 36, 46, 50, 52, 53, 56, 57, 58, 72, 79, 95	93.43 ± 0.01	89.33 ± 0.09	85.71 ± 0.02
	5 17	8, 16, 18, 20, 23, 24, 28, 31, 32, 33, 39, 42, 43, 49, 72, 76, 79	91.58 ± 0.27	84.44 ± 0.16	78.83 ± 0.02
Daubechies (<i>db</i>)	1 16	4, 5, 11, 17, 28, 35, 37, 39, 44, 51, 52, 56, 65, 88, 91, 95	93.70 ± 0.42	84.84 ± 0.33	80.82 ± 0.13
	2 19	8, 16, 17, 20, 27, 28, 35, 36, 37, 48, 52, 57, 60, 63, 64, 65, 80, 87, 88	91.71 ± 1.07	85.71 ± 0.20	81.83 ± 0.11
	3 19	4, 7, 8, 24, 26, 28, 32, 34, 35, 36, 46, 53, 54, 58, 61, 76, 83, 87, 91	91.40 ± 0.02	85.60 ± 0.47	78.81 ± 0.56
	4 23	4, 12, 17, 22, 23, 26, 35, 40, 41, 42, 44, 50, 51, 54, 55, 60, 62, 63, 65, 67, 72, 76, 94	94.21 ± 0.11	89.55 ± 0.36	83.54 ± 0.71
	5 21	4, 8, 17, 22, 23, 24, 26, 28, 31, 40, 43, 58, 64, 65, 67, 72, 73, 80, 81, 88, 89	93.79 ± 0.20	89.75 ± 0.56	85.69 ± 0.18
	6 24	4, 6, 16, 17, 19, 21, 22, 26, 28, 29, 32, 35, 38, 41, 43, 53, 75, 76, 79, 80, 82, 86, 90, 91	94.87 ± 0.04	90.15 ± 0.29	87.00 ± 0.18
	7 19	5, 7, 10, 12, 14, 15, 21, 26, 28, 37, 40, 50, 57, 59, 65, 83, 89, 92, 94	93.28 ± 0.38	86.87 ± 0.09	81.77 ± 0.25
	8 17	4, 14, 17, 18, 19, 24, 26, 28, 29, 32, 34, 50, 62, 65, 66, 73, 80	91.56 ± 0.25	84.10 ± 0.29	78.21 ± 0.16
	9 18	5, 22, 26, 28, 35, 36, 37, 39, 44, 46, 47, 56, 62, 77, 86, 88, 92, 93	92.65 ± 0.01	84.30 ± 0.02	79.04 ± 0.33
	10 22	5, 9, 11, 12, 14, 15, 16, 26, 36, 37, 40, 46, 47, 53, 55, 60, 68, 70, 80, 91, 92, 93	93.72 ± 0.07	85.87 ± 0.13	78.17 ± 0.31
Fejer-Krovkin (<i>fk</i>)	4 19	10, 12, 17, 28, 29, 32, 41, 43, 58, 72, 76, 78, 83, 85, 87, 88, 93, 94, 96	91.89 ± 0.47	82.63 ± 0.36	79.01 ± 0.13
	6 20	4, 7, 17, 22, 25, 32, 34, 35, 37, 39, 44, 47, 48, 53, 54, 61, 64, 80, 86, 90	90.60 ± 0.38	82.50 ± 0.11	77.09 ± 0.27
	8 21	2, 6, 8, 16, 28, 36, 39, 40, 42, 48, 51, 59, 60, 64, 68, 69, 70, 71, 72, 91, 93	92.23 ± 0.25	85.93 ± 0.42	79.24 ± 0.02
	14 16	3, 15, 19, 26, 28, 31, 32, 48, 52, 55, 57, 58, 62, 72, 77, 85	90.93 ± 0.07	84.24 ± 0.38	79.44 ± 0.16
	18 20	5, 8, 15, 16, 24, 26, 31, 34, 37, 49, 52, 61, 62, 76, 79, 80, 85, 88, 92, 94	92.88 ± 0.11	86.47 ± 0.29	80.49 ± 1.34
	22 21	4, 7, 8, 9, 20, 21, 22, 25, 26, 34, 45, 51, 52, 62, 64, 69, 75, 76, 81, 84, 95	92.74 ± 0.36	87.29 ± 0.45	81.98 ± 0.27
Symlets (<i>sym</i>)	2 20	4, 5, 9, 11, 21, 23, 26, 28, 29, 32, 35, 41, 46, 52, 67, 69, 73, 79, 80, 88	91.89 ± 0.02	83.86 ± 0.02	78.41 ± 0.63
	3 19	2, 4, 5, 12, 15, 21, 28, 37, 43, 44, 45, 51, 57, 62, 65, 73, 76, 94, 95	92.61 ± 0.38	87.18 ± 0.33	82.74 ± 0.13
	4 18	3, 17, 19, 21, 26, 28, 40, 52, 54, 60, 65, 72, 74, 79, 85, 90, 92, 95	91.56 ± 0.13	85.89 ± 0.16	80.75 ± 0.49
	5 23	10, 16, 17, 18, 21, 22, 26, 28, 29, 31, 39, 56, 64, 72, 75, 81, 82, 85, 91, 92, 93, 95, 96	93.41 ± 0.09	87.96 ± 0.33	80.96 ± 0.25
	6 16	4, 16, 17, 21, 27, 28, 37, 45, 60, 61, 66, 67, 68, 77, 80, 92	91.36 ± 0.16	86.96 ± 0.11	83.28 ± 0.22
	7 18	5, 9, 16, 19, 20, 28, 41, 47, 50, 52, 64, 67, 70, 78, 80, 78, 90, 95	90.33 ± 0.02	83.59 ± 0.02	79.50 ± 0.25
	8 15	4, 23, 28, 29, 32, 39, 46, 51, 52, 60, 67, 70, 76, 78, 88	90.13 ± 0.18	86.65 ± 0.25	84.04 ± 1.09

PSO-SVM sarmalayıcı yaklaşımıyla ‘*db6*’ dalgacık ailesine dayalı 2D-DWT yöntemiyle oluşturulan özelliklerden yirmi dört özellik alt kümesi seçilmektedir. Seçilen 24 özellik ile oluşturulan CNN, SVM ve KNN sınıflandırıcılarının performansları sırasıyla %94.87, %90.15

ve %87.00 olarak ölçülmektedir. PSO ve SVM'den oluşan sarmalayıcı yaklaşım için, SVM ve KNN sınıflandırıcı algoritmaları ile oluşturulan modeller arasında en iyi performans “*db6*” dalgacık ailesi tarafından üretilen özneliklerle elde edilmektedir. CNN sınıflandırıcısının performansı ‘*bior2.6*’ hariç dalgacık aileleri için %90'ın üzerinde ölçülmektedir. SVM sınıflandırıcısının performansı, ‘*bior1.1*’, ‘*bior1.3*’, ‘*bior1.5*’, ‘*bior2.6*’, ‘*coif5*’, ‘*db1*’, ‘*db8*’, ‘*db9*’, ‘*fk4*’, ‘*fk6*’, ‘*fk14*’, ‘*sym2*’ ve ‘*sym7*’ hariç dalgacık aileleri için %85'in üzerinde ölçülmektedir. KNN sınıflandırıcısının performansı, ‘*bior1.3*’, ‘*bior1.5*’, ‘*bior2.6*’, ‘*bior3.3*’, ‘*coif1*’, ‘*coif5*’, ‘*db3*’, ‘*db8*’, ‘*db9*’, ‘*db10*’, ‘*fk4*’, ‘*fk6*’, ‘*fk8*’, ‘*fk14*’, ‘*sym2*’ ve ‘*sym7*’ hariç dalgacık aileleri için %80'in üzerinde ölçülmektedir. CNN sınıflandırıcısının performansının SVM ve KNN sınıflandırıcılarına göre daha üstün olduğu görülmektedir.

CNN'nin model yapısı ve girdi boyutu dikkate alındığında, önerilen sınıflandırma modelinin FPA-SVM sarmalayıcı yaklaşımı tarafından seçilen daha az özellik ile yüksek performansa sahip olması nedeniyle model karmaşıklığının düşük olduğu söylenebilmektedir. Çizelge 4.5 ve Çizelge 4.6 birlikte değerlendirildiğinde hem sınıflandırma modeli performansı hem de seçilen öznelik sayısı dikkate alındığında önerilen FPA tekniğinin CNN, SVM ve KNN sınıflandırıcıları için PSO algoritmasına göre başarılı olduğu görülmektedir. Çalışmada önerilen FPA-SVM sarmalayıcı yaklaşımı ile seçilen öznelikler için 50 kez eğitim-doğrulama işlemi sonucunda elde edilen CNN, SVM ve KNN sınıflandırıcı model performansları birbirleriyle karşılaştırılmıştır.

Şekil 4.6'daki ‘*bior*’, ‘*coif*’, ‘*db*’, ‘*fk*’ ve ‘*sym*’ dalgacık aileleridir. CNN sınıflandırıcısı ile elde edilen modellerin performanslarının hem SVM hem de KNN sınıflandırıcıları ile elde edilen modellerin performanslarından açıkça daha yüksek olduğu görülmektedir. Belirtilen dalgacık aileleri için SVM sınıflandırıcı performansının KNN sınıflandırıcı performansından daha yüksek olduğu da belirtilmelidir. ‘*sym7*’ Dalgacık ailesi için önerilen FPA-SVM sarmalayıcı yaklaşımı ile seçilen özneliklerle oluşturulan tüm sınıflandırıcıların performansı en iyi performansa sahiptir. Önerilen FPA optimizasyon tekniğinin, PSO'ya kıyasla CNN sınıflandırıcı performansını yaklaşık %5 ve SVM ve KNN sınıflandırıcı performanslarını yaklaşık %8 oranında iyileştirmesi dikkat çekicidir. Ayrıca ‘*db6*’ dalgacık ailesi için PSO-SVM sarmalayıcı yaklaşımı ile seçilen öznelikler ile oluşturulan tüm sınıflandırıcıların performansının en iyi performansa sahip olduğu görülmektedir. En iyi sınıflandırma performansını sağlayan dalgacık aileleri için FPA-SVM ve PSO-SVM sarmalayıcı yaklaşımları

tarafından seçilen özelliklerle oluşturulan çeşitli sınıflandırıcıların performansları, doğruluk, kesinlik, geri çağırma ve F1-skoru performans metrikleri Çizelge 4.7'de sunulmuştur.


Çizelge 4.7 En iyi sınıflandırma performansını sağlayan dalgacık aileleri için önerilen FPA-SVM ve PSO-SVM sarmalayıcı yaklaşımları tarafından seçilen özelliklerle oluşturulan çeşitli sınıflandırıcıların performanslarının karşılaştırılması.

Özellik Seçim Yöntemi	Dalgacık Sınıflandırıcı	Sınıflandırıcı	Doğruluk (%)	Kesinlik (%)	Geri çağırma (%)	F1 skoru (%)
PSO-SVM	<i>db6</i>	CNN	94.87	95.06	94.61	94.77
		SVM	90.15	90.21	89.62	89.73
		KNN	87.00	87.64	85.86	86.26
FPA-SVM	<i>sym7</i>	CNN	99.55	99.52	99.60	99.56
		SVM	97.54	97.58	96.44	96.92
		KNN	93.97	94.25	93.82	93.84


Çalışmada ‘*sym7*’ dalgacık ailesine dayalı 2D-DWT sinyal işleme yöntemini ve FPA-SVM ve CNN sınıflandırıcıdan oluşan sarmalayıcı yaklaşımı içeren en iyi performans gösteren model NVIDIA'ya gömülmektedir. İHA üzerinde Jetson Nano yapay zekâ (Artificial Intelligence -AI) uygulama geliştirme kiti ile elma, üzüm ve domates bitkilerinde gerçek zamanlı sınıflandırma testleri yapılmaktadır. Test görüntüleri üzerinde yapılan deneyler sonucunda elde edilen sonuçlar bir karışıklık matrisi şeklinde Şekil 4.7'de sunulmaktadır. Gerçek zamanlı olarak çalıştırılan modelin 12 hastalık sınıfından sadece 2 tanesi için çok düşük düzeyde sınıflandırma hatasına sahip olduğu görülmektedir. Model, 84 üzüm siyah kızamık test verisinden 2 tanesini üzüm siyah çürüklük hastalık sınıfı olarak tahmin etmektedir. Benzer şekilde model, 85 domates bakteriyel benek test verisinden 2 tanesini elma sağlıklı olarak sınıflandırır. Önerilen model hem bitki türlerini hem de bitki hastalıklarını yüksek doğrulukla gerçek zamanlı olarak sınıflandırabilmektedir.




Şekil 4.5 Gerçek zamanlı testinde kullanılan insansız hava aracı.




(a)




(b)



(c)



(d)



(e)

Şekil 4.6 a) Biorthogonal, b) Coiflets, c) Daubechies, d) Fejer-Korovkin ve e) Simlets dalgacık aileleri için çalışmada kullanılan sınıflandırıcıların performansları.

Ayrıca çalışmada önerilen model dışında oluşturulan toplam 227 model, Şekil 4.5'de görülen İHA üzerinde NVIDIA Jetson Nano AI uygulama geliştirme kiti üzerine gömülerek tüm modellerin performansları ölçülmektedir. Modellerin performansları hesaplama süresi açısından değerlendirildiğinde, önerilen modelin hesaplama süresinin çalışmadaki en iyi ikinci

modele göre %8.1 daha iyi olduğu görülmektedir. Deneysel çalışmalar sonucunda, hesaplama karmaşıklığı düşük bir optimizasyon algoritması ile en az sayıda öznelik seçilerek oluşturulan sağlam melez sınıflandırma modelimizin bitki yaprak hastalıklarını gerçek zamanlı hassasiyetle sınıflandırabildiği sonucuna varılmaktadır.

Doğru Sınıf	domates (bakteriyel benek)	97.6%					2.4%						97.6%	2.4%
	domates (geç yanıklık)		100.0%										100.0%	
	domates (sarı yaprak kıvrıklık)			100.0%									100.0%	
	domates (sağlıklı)				100.0%								100.0%	
	elma (kara leke)					100.0%							100.0%	
	elma (memeli mantarı)						100.0%						100.0%	
	elma (sağlıklı)							100.0%					100.0%	
	elma (siyah çürüklük)								100.0%				100.0%	
	üzüm (sağlıklı)									100.0%			100.0%	
	üzüm (siyah kızamık)										97.6%	2.4%	97.6%	2.4%
	üzüm (siyah çürüklük)											100.0%	100.0%	
	üzüm (yaprak yanıklık)												100.0%	100.0%
		Tahmin Edilen Sınıf												

Şekil 4.7 Önerilen elma, üzüm ve domates bitki yaprak hastalığı sınıflandırma modeli için karışıklık matrisi.

BÖLÜM 5

SONUÇLAR VE ÖNERİLER

Bitki hastalıklarının erken dönemde tespiti uygun tedavi için büyük önem taşımaktadır. Bitki yaprak hastalıklarının görsel muayene yerine otomatik tespiti ve sınıflandırılması, tarımsal ürün verimliliğinin artmasına katkıda bulunmaktadır. Bu çalışmada, elma, üzüm ve domates bitkilerindeki hastalıkları gerçek zamanlı olarak yüksek doğrulukla sınıflandırmak için makine öğrenmesi ve derin öğrenme algoritmalarını içeren sürü optimizasyonu destekli özellik seçimine dayalı yeni bir sağlam melez sınıflandırma modeli önerilmektedir. Önerilen model ‘*sym7*’ dalgacık ailesine dayalı 2D-DWT sinyal işleme yöntemini, FPA-SVM'den oluşan sarmalayıcı yaklaşımı ve CNN sınıflandırıcısını içermektedir. Modelin sağlam olması için Biorthogonal, Coiflet, Daubechies, Fejer–Korovkin ve symlet gibi çeşitli dalgacık ailelerinden çıkarılan öznitelikler 2D-DWT yöntemiyle kullanılmaktadır. Her dalgacık ailesi için sınıflandırıcı performansını yüksek tutan özellikler, FPA ve SVM'den oluşan sarmalayıcı bir yaklaşımla seçilerek, modelin hesaplama karmaşıklığı minimum düzeyde tutulmaktadır. CNN sınıflandırma modeli, sınıflandırma performansını yüksek tutabilecek en düşük öznitelik sayısı kullanılarak oluşturulmaktadır. Modelin karmaşıklığını en aza indirmek ve model hiper parametre probleminin üstesinden gelmek için özellik çıkarma katmanı olmadan tek bir sınıflandırma katmanına sahip CNN sınıflandırıcısı kullanılmaktadır. Bitki yaprak hastalığı sınıflandırması için önerilen model, İHA üzerindeki NVIDIA Jetson Nano AI geliştirme kitine gömülüdür ve gerçek zamanlı performansı test edilmektedir. Elde edilen deneysel sonuçlar, önerilen modelin belirtilen bitki yaprak hastalıklarını gerçek zamanlı olarak yüksek doğrulukla tespit edip sınıflandırabildiğini kanıtlamaktadır. Önerilen hızlı ve düşük hesaplama maliyetli sınıflandırma modeli, bitki yapraklarını erken bir aşamada yüksek doğrulukla sınıflandırarak tarımsal verimliliğin artmasına katkıda bulunmaktadır. Gelecekteki çalışmalarda, benzer yaprak görüntülerinde spesifik olmayan hastalıkları tespit etmek ve sınıflandırmak için iki boyutlu görüntülerdeki kaotiklikle başa çıkabilen algoritmalar, sınıflandırıcı model yapıları üzerinde test edilecektir.



KAYNAKLAR

- Abdel-Basset M, El-Shahat D, El-Henawy I and Sangaiah A K** (2018) A Modified Flower Pollination Algorithm for the Multidimensional Knapsack Problem: Human-Centric Decision Making. *Soft Computing*, 22:4221–4239.
- Abdel-Basset M and Shawky L A** (2019) Flower Pollination Algorithm: A Comprehensive Review. *Artificial Intelligence Review*, 52: 2533–2557.
- Ali H, Lali M I, Nawaz M Z, Sharif M and Saleem B A** (2017) Symptom Based Automated Detection of Citrus Diseases Using Color Histogram and Textural Descriptors. *Computers and Electronics in Agriculture*, 138: 92–104.
- Almadhor A, Rauf H T, Lali M I U, Damaševičius R, Alouffi B and Alharbi A** (2021) AI-driven Framework for Recognition of Guava Plant Diseases through Machine Learning from DSLR Camera Sensor Based High Resolution Imagery. *Sensors*, 21: 3830.
- Anderson P K, Cunningham A A, Patel N G, Morales F J, Epstein P R and Daszak P** (2004) Emerging Infectious Diseases of Plants: Pathogen Pollution, Climate Change And Agrotechnology Drivers. *Trends in Ecology and Evolution*, 19:535–544.
- Atila Ü, Uçar M, Akyol K, Uçar E** (2021) Plant Leaf Disease Classification using Efficientnet Deep Learning Model. *Ecological Informatics*, 61: 101182.
- Barbedo J G A** (2018) Impact of Dataset Size and Variety on the Effectiveness of Deep Learning and Transfer Learning for Plant Disease Classification. *Computers and Electronics in Agriculture*, 153: 46–53.
- Barbedo J G A, Koenigkan L V and Santos T T** (2016) Identifying Multiple Plant Diseases using Digital Image Processing. *Biosystems Engineering*, 147: 104–116.
- Belasque L, Gasparoto M C G and Marcassa L G** (2008) Detection of Mechanical and Disease Stresses in Citrus Plants by Fluorescence Spectroscopy. *Applied Optics*, 47:11:1922-1926.
- Bolognesi C** (2003) Genotoxicity of Pesticides: A Review of Human Biomonitoring Studies. *Mutation Research*, 543:3: 251–272.
- Brasier C M** (2008) The Biosecurity Threat to the UK and Global Environment from International Trade in Plants. *Plant Pathology*, 57:792–808.

KAYNAKLAR (devam ediyor)

- Bruno G and Sparapano L** (2007) Effects of three esca-associated fungi on *Vitis vinifera* L.: V. Changes in the chemical and biological profile of xylem sap from diseased cv. Sangiovese vines. *Physiological and Molecular Plant Pathology*, 71:210-229.
- Carvalho F P** (2006) Agriculture, Pesticides, Food Security and Food Safety. *Environmental Science and Policy*, 9:7:685-692.
- Chadha S, Sharma M and Sayyed A** (2021) In *Microbial Management of Plant Stresses*. 1, Woodhead Publishing, Cambridge, UK Advances in sensing plant diseases by imaging and machine learning methods for precision crop protection, 157–183.
- Cohen A and Sun Q** (1993) An Arithmetic Characterization of the Conjugate Quadrature Filters Associated to Orthonormal Wavelet Bases. *SIAM Journal of Mathematical Analysis*, 24: 1355–1360.
- Darwish A, Ezzat D and Hassanien A E** (2020) An Optimized Model Based on Convolutional Neural Networks and Orthogonal Learning Particle Swarm Optimization Algorithm for Plant Diseases Diagnosis. *Swarm and Evolutionary Computation*, 52: 100616.
- Daubechies I** (1988) Orthonormal Bases of Compactly Supported Wavelets. *Communications on Pure and Applied Mathematics*, 41: 909–996.
- Daubechies I** (1990) The Wavelet Transform, Time-Frequency Localization and Signal Analysis. *IEEE Transactions on Information Theory*, 36: 961–1005.
- Daubechies I** (1992) Ten Lectures on Wavelets, *Society for Industrial and Applied Mathematics*, ISBN 0-89871-274-2, Philadelphia, PA, USA.
- Dean R A, Talbot N J, Ebbolle D J, Farman M L, Mitchell T K and Orbach M J** (2005) The Genome Sequence of the Rice Blast Fungus *Magnaporthe Grisea*. *Nature*, 434:980–986.
- Fang Y and Ramasamy R P** (2015) Current and Prospective Methods for Plant Disease Detection. *Biosensors*, 5:537–561.
- Gonzalez R C and Woods R E** (2002) *Digital Image Processing*, 4th edition, ISBN: 978-0-13-335672-4, Pearson Education, Rotherham, UK.
- Grossmann A and Morlet J** (1984) Decomposition of Hardy Functions Into Square Integrable Wavelets of Constant Shape. *SIAM Journal of Mathematical Analysis*, 15: 723–736.
- Gu J, Wang Z, Kuen J, Ma L, Shahroudy A, Shuai B, Liu T, Wang X, Wang G, Cai J and Chen T** (2018) Recent Advances in Convolutional Neural Networks. *Pattern Recognition*, 77: 354–377.
- Guenther A** (1997) Seasonal and Spatial Variations in Natural Volatile Organic Compound Emissions. *Ecological Applications*, 7:1:34-45.

KAYNAKLAR (devam ediyor)

- Kamal K C, Yin Z, Wu M and Wu Z** (2019) Depthwise Separable Convolution Architectures for Plant Disease Classification. *Computers and Electronics in Agriculture*, 165: 104948.
- Karasu S and Saraç Z** (2022) The Effects on Classifier Performance of 2D Discrete Wavelet Transform Analysis and Whale Optimization Algorithm for Recognition of Power Quality Disturbances. *Cognitive Systems Research*, 75: 1–15.
- Keinert F** (1994) Biorthogonal Wavelets for Fast Matrix Computations. *Applied and Computational Harmonic Analysis*, 1: 147–156.
- Kim C H and Aggarwal R** (2000) Wavelet Transforms in Power Systems 1. General Introduction to the Wavelet Transforms. *Power Engineering Journal*, 14: 81–87.
- Li L, Cai H, Han H, Jiang Q and Ji H** (2020) Adaptive Short-Time Fourier Transform and Synchrosqueezing Transform for Non-Stationary Signal Separation. *Signal Processing*, 166: 107231.
- Li Y, Nie J and Chao X** (2020) Do We Really Need Deep CNN for Plant Diseases Identification. *Computers and Electronics in Agriculture*, 178: 105803.
- López M M, Bertolini E, Olmos A, Caruso P, Gorris M T, Llop P, Penyalver R and Cambra M** (2003) Innovative Tools for Detection of Plant Pathogenic Viruses and Bacteria. *International Microbiology*, 6:233-243.
- Ma C, Zhang H H and Wang X** (2014) Machine Learning for Big Data Analytics in Plants. *Trends in Plant Science*, 19: 798–808.
- Mallat S G** (1989) A Theory for Multiresolution Signal Decomposition: the Wavelet Representation. *IEEE Transactions on Pattern Anaysis and Machine Intelligence*, 11: 674–693.
- Mallat S G** (1999) *A Wavelet Tour of Signal Processing*, 2nd edition, ISBN: 978-0-12-466606-1, Elsevier Education, California, USA.
- Miller S A, Beed F D and Harmon C L** (2009) Plant Disease Diagnostic Capabilities and Networks. *Annual Review Phytopatholgy*, 47: 15–38.
- Mohanty S P, Hughes D P and Salathé M** (2016) Using Deep Learning for Image-Based Plant Disease Detection. *Frontiers in Plant Science*, 7: 1419.
- Monzón L, Beylkin G and Hereman W** (1999) Compactly Supported Wavelets Based on Almost Interpolating and Nearly Linear Phase Filters (Coiflets). *Applied and Computational Harmonic Analysis*, 7: 184–210.
- Nielsen M** (2001) On the Construction and Frequency Localization of Finite Orthogonal Quadrature Filters. *Journal of Approximation Theory*, 108: 36–52.

KAYNAKLAR (devam ediyor)

- Oerke E C** (2006) Crop Losses to Pests. *Journal of Agricultural Science*, 144:31–43.
- Okamoto H, Suzuki Y, Kataoka T and Sakai K** (2009) Unified Hyperspectral imaging Methodology for Agricultural Sensing Using Software Framework. *Acta Horticulturae*, 824:49-56.
- Ons L, Bylemans D, Thevissen K and Cammue B P** (2020) Combining Biocontrol Agents with Chemical Fungicides for Integrated Plant Fungal Disease Control. *Microorganisms*, 8: 1930.
- Ozguven M M and Altas Z** (2022) A New Approach to Detect Mildew Disease on Cucumber (Pseudoperonospora Cubensis) Leaves with Image Processing. *Journal of Plant Pathology*, 104:1–10.
- Pimentel D, Zuniga R and Morrison D** (2005) Update on the Environmental and Economic Costs Associated with Alien-Invasive Species in the United States. *Ecological Economics*, 52:3:273-288.
- Roberts M J, Schimmelpfennig D, Ashley E, Livingston M, Ash M and Vasavada U** (2006) The Value of Plant Disease Early-Warning Systems: A Case Study of USDA's Soybean Rust Coordinated Framework. *United States Department of Agriculture.. Economic Research Service No.* 18:1-19.
- Saeed F, Khan M A, Sharif M, Mittal M, Goyal L M and Roy S** (2021) Deep Neural Network Features Fusion and Selection Based on PLS Regression with an Application for Crops Diseases Classification. *Applied Soft Computing*, 103: 107164.
- Sarwar M** (2015) The Dangers of Pesticides Associated with Public Health and Preventing of the Risks. *International Journal of Bioinformatics and Biomedical Engineering*. 1:2:130–136.
- Savary S, Ficke A, Aubertot J and Hollier C** (2012) Crop Losses due to Diseases and their Implications for Global Food Production Losses and Food Security. *Food Security*, 4: 519–537.
- Savary S, Willocquet L, Pethybridge S J, Esker P, McRoberts N and Nelson** (2019) The Global Burden of Pathogens and Pests on Major Food Crops. *Nature Ecology and Evolution*, 3:430–439.
- Singh V and Misra A K** (2017) Detection of Plant Leaf Diseases using Image Segmentation and Soft Computing Techniques. *Information Processing in Agriculture*, 4: 41–49.
- Strange R N and Scott P R** (2005) Plant Disease: A Threat to Global Food Security. *Annual Review Phytopathology*, 43: 83–116.
- Tan L, Lu J and Jiang H** (2021) Tomato Leaf Diseases Classification Based on Leaf Images: a Comparison Between Classical Machine Learning and Deep Learning Methods. *AgriEngineering*, 3: 542–558.

KAYNAKLAR (devam ediyor)

- Tewari V K, Pareek C M, Lal G, Dhruw L K and Singh N** (2020) Image Processing Based Real-Time Variable-Rate Chemical Spraying System for Disease Control in Paddy Crop. *Artificial Intelligence Agriculture*, 4: 21–30.
- Thangaraj R, Anandamurugan S and Kaliappan V K** (2021) Automated Tomato Leaf Disease Classification using Transfer Learning-Based Deep Convolution Neural Network. *Journal of Plant Diseases and Protection*, 128: 73–86.
- Too E C, Yujian L, Njuki S and Yingchun L** (2019) A Comparative Study of Fine-Tuning Deep Learning Models for Plant Disease Identification. *Computers and Electronics in Agriculture*, 161: 272–279.
- Vallat A, Gu H and Dorn S** (2005) How Rainfall, Relative Humidity and Temperature Influence Volatile Emissions from Apple Trees in Situ. *Phytochemistry*, 66:1540-1550.
- Vuorinen T, Nerg M A, Syrjälä L, Peltonen P and Holopainen J K** (2007) Epirrita Autumnata Induced VOC Emission of Silver Birch Differ from Emission Induced by Leaf Fungal Pathogen. *Arthropod–Plant Interactions*, 1:159-165.
- Wen D M, Chen M X, Zhao L, Ji T, Li M and Yang X T** (2019) Use of Thermal Imaging and Fourier Transform Infrared Spectroscopy for the Pre-Symptomatic Detection of Cucumber Downy Mildew. *European Journal of Plant Pathology*, 155: 405–416.
- Yang X S** (2012) Flower Pollination Algorithm for Global Optimization. *In: Unconventional Computation and Natural Computation: 11th International Conference*, 3-7 Eylül 2012, Orléan, Fransa, Proceedings 11, Springer Berlin Heidelberg, Almanya, 240-249.
- Zhang, N, Yang G, Pan Y, Yang X, Chen L and Zhao C** (2020) A Review of Advanced Technologies and Development for Hyperspectral-Based Plant Disease Detection in the Past Three Decades. *Remote Sensing*, 12: 3188.
- Zhong J and Huang Y** (2010) Time-Frequency Representation Based on an Adaptive Short-Time Fourier Transform. *IEEE Transactions on Signal Processing*, 58: 5118–5128.



ÖZGEÇMİŞ

İlayda YAĞ, 2021 yılında Zonguldak Bülent Ecevit Üniversitesi Elektrik-Elektronik Mühendisliği bölümünden mezun oldu. 2021 yılında Zonguldak Bülent Ecevit Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği bölümünde tezli yüksek lisans eğitime başladı ve hala eğitime devam etmektedir. Araştırma ve ilgi alanları arasında görüntü işleme teknikleri, yapay zekâ, derin öğrenme ve optimizasyon algoritmaları bulunmaktadır.

